



TITLE:

リモートセンシング画像とGISの水文解析への応用(Dissertation_全文)

AUTHOR(S):

児島, 利治

CITATION:

児島, 利治. リモートセンシング画像とGISの水文解析への応用. 京都大学, 1998, 博士(工学)

ISSUE DATE:

1998-03-23

URL:

<https://doi.org/10.11501/3135455>

RIGHT:

リモートセンシング画像とGISの水文解析への応用

平成9年12月

児島利治

目 次

1	序論	1
2	ラスタ型空間情報とそのスケールアップの方法について	5
2.1	概説	5
2.2	データを間引く方法	6
2.3	算術平均による方法	7
2.4	内挿法を用いたアルゴリズム	7
2.5	MTF を応用した低分解能化アルゴリズム	8
2.6	最大頻度に基づく方法	11
2.7	結語	11
3	リモートセンシング画像の分解能が土地被覆分類精度に及ぼす影響	13
3.1	概説	13
3.2	対象流域と使用空間情報	14
3.3	定量的分類精度評価手法	14
3.4	疑似低分解能画像の発生と分類精度評価	17
3.5	疑似 TM 画像と疑似 AVNIR 画像の模擬発生と分類・精度評価	20
3.6	結語	22
4	リモートセンシング画像の分解能が植生指標・蒸発散量推定値に及ぼす影響	33
4.1	概説	33
4.2	植生指標について	34
4.3	対象流域と使用空間情報	34
4.4	分光反射率の算定	35
4.4.1	分光反射率の定義	36
4.4.2	入射分光放射束密度の算定	36
4.4.3	分光放射束密度の補正	38
4.4.4	反射分光放射束密度の算定	39
4.5	空間分解能が NDVI に及ぼす影響	40
4.5.1	領域全体の統計量について	41
4.5.2	土地被覆クラス毎の統計量	42

4.5.3	ヒストグラムによる考察	45
4.6	NDVI を用いた月蒸発散量の推定	45
4.7	空間分解能が月蒸発散量推定値に及ぼす影響	46
4.7.1	領域全体の統計量	47
4.7.2	土地被覆クラス毎の統計量	49
4.7.3	ヒストグラムによる考察	49
4.8	土地利用の割合による月蒸発散量の推定	52
4.8.1	F-C-U ダイアグラム	52
4.8.2	日本全国 2km メッシュ土地利用データを用いた月蒸発散量の推定	52
4.9	結語	54
5	ラスター型空間情報の分解能が分布型流出解析結果に及ぼす影響	71
5.1	概説	71
5.2	対象流域	71
5.3	セル分布型流出モデル	72
5.3.1	セル分布型流出モデルの概要	72
5.3.2	実河道の近似	73
5.3.3	落水線図の作成	73
5.3.4	モデル定数の決定	78
5.3.5	流出モデルの検証	80
5.4	矢田川流域への適用	89
5.4.1	水文資料の整理	89
5.4.2	雨量の空間分布の考慮	91
5.4.3	有効雨量の算定	92
5.4.4	河道幅一定モデル (Model A) への適用	92
5.4.5	河道幅考慮モデル (Model B) への適用	103
5.4.6	モデルの分解能と流出の遅れの関係	120
5.5	結語	129
6	結論	143
謝辞	147

第 1 章

序論

レーダや人工衛星をはじめとするリモートセンシング技術は、最近著しい進歩を遂げている。日本においても、JERS-1(Japanese Earth Resources Satelllite-1) や ADEOS(Advanced Earth Observing Satellite) シリーズ, TRMM(Tropical Rainfall Measuring Mission) のような地球環境監視のための衛星が打ち上げられ、また打ち上げが計画されている。リモートセンシング技術は、広範囲の均質なデータが同時に得られる、人の踏査できない地域のデータも入手可能である等の点で有用であり、これまで地点での観測に頼ってきた水文学に大きな変化をもたらしつつある。例えば、蒸発散量の推定には、気温や風速などの気象観測所(すなわち地点)において観測される物理量を用いる推定法¹⁾が提示されている。しかし、ある地点において観測されたパラメタを用いただけでは、その地点およびその周辺の極々狭い領域での蒸発散量が推定されるのみである。それに対して、広域の情報を得られるリモートセンシングデータを用いて、蒸発散量を推定しようとする研究がなされている²⁾³⁾。

近年、リモートセンシング画像は、Landsat/TM(空間分解能 30 m) や SPOT/HRV(20 m) のように非常に高い空間分解能を持つに至っている。民間商業衛星においては、スペース・イメージング社の CRSS, オービタル・イメージング社の OrbView 等のように、ここ 1～2 年のうちにパンクロで 1 m 程度、マルチスペクトルで 3～4 m という極めて高い分解能の画像の提供が開始されようとしている⁴⁾。降雨レーダーは、日本全国をカバーするように整備され、また、地表面条件の空間情報としては、国土数値情報や 10 m グリッドで土地利用情報を保存している細密数値情報などが整備されている⁵⁾。数値標高データ (Digital Elevation Model; DEM) に関しては、従来の国土数値情報の分解能 250 m に代わり、日本全国で分解能 50 m の DEM(数値地図 50 m メッシュ(標高))⁵⁾が整備され、年々、高密度・高分解能の空間情報が利用可能となっている。

こうしたリモートセンシングデータ、DEM 等の空間情報の高分解能化の動きの一方で、地球規模・大陸規模の観点から環境問題、水・熱収支の問題などを考慮することの重要性が認識され、GEWEX(全地球エネルギー・水循環観測実験計画) とその関連計画 (GCIP, GAME ほか) 等のように、いくつもの国際共同研究が実行されつつある。地球規模 (グローバルスケール) での気候変動や環境の変化に関する定量的予測法として大気大循環モデル (GCM: General Criculation Model) が用いられる。GCM では 200 km 以上のグリッドサイズが用

いられる。これは、日本の流域スケールから見ると非常に大きなものである。基本的に、風速、気温、蒸発散量、流出量などの物理量は、地点や比較的狭い範囲で観測されたり、小スケールにおいて推定法が開発されてきたものである。したがって、それら小スケールでの観測結果や推定法をどのようにしてグローバルスケールへ拡張するかは重要な問題の一つとなっている。対象とする物理量やパラメタによっては、スケールアップによって重要な情報が損なわれ、その結果として、解析・予測結果に大きな誤りを招来するかも知れないからである。

以上のことをふまえて、本研究では、高分解能のリモートセンシングデータや土地利用情報などの数値地図とそれらを統合的に処理する地理情報システム (GIS) の水文解析への応用手法に関する研究を行う。特に、リモートセンシングデータ、ラスタ型空間情報を空間的にスケールアップ (aggregate) した際に、推定される水文解析結果にどのような影響があるかについて、実際の河川流域への適用を通じて検討を行う。以下に本論文の構成を簡単に述べる。

第1章では、本論文の背景と目的について記す。

第2章では、ラスタ型空間情報の種類とそのスケールアップ (すなわち分解能を粗くすること、低分解能化) の手法について考察する。

第3章では、リモートセンシング画像の水文解析への応用手法としてリモートセンシング画像の土地被覆分類を取り上げ、土地被覆分類精度とリモートセンシング画像の空間分解能との関係について考察する。

第4章では、リモートセンシング画像から蒸発散量を推定する手法について検討を行い、基となるリモートセンシング画像の空間分解能が推定される蒸発散量に与える影響について考察する。また、土地利用情報のみから領域内の蒸発散量を推定する手法を提案する。

第5章では、リモートセンシング画像や DEM といったラスタ型空間情報を用いた洪水流出モデルを提案し、そのモデルによる流出解析の結果とラスタ型空間情報の分解能との関係について考察する。

第6章では、以上の考察をまとめて結論とする。

参考文献

- 1) 中川慎治: 蒸発散の概念とその適用性について, 筑波大学水理実験センター報告, No. 6, pp. 53-62, 1982.
- 2) 多田 毅・風間 聡・沢本正樹: NDVI を用いた広葉樹林帯の蒸発散分布推定, 水文・水資源学会誌, Vol. 7, No. 2, pp. 114-119, 1994.
- 3) Seevers, P. M. and R. W. Ottmann: Evapotranspiration estimation using a normalized difference vegetation index transformation of satellite data, Hydrological Sciences Journal, Vol. 39, No. 4, pp. 333-345, 1994.
- 4) 岡本晴人: 高解像度衛星の商業化とデータ利用に向けて, 写真測量とリモートセンシング, Vol. 35, No. 1, pp. 62-63, 1996.

- 5) 財団法人 日本地図センター: 数値地図ユーザーズガイド (改訂版), p. 423, 1994.

第 2 章

ラスター型空間情報とそのスケールアップの方法について

2.1 概説

一口にラスター型空間情報と言っても様々な種類が存在する。ラスター型空間情報をスケールアップする際にも、そのラスターデータがどのような内容のものか判断し、それに応じたアルゴリズムによってスケールアップする必要がある。

ラスター型空間情報は、連続型 (continual) と主題型 (thematic) に分類される。連続型データとは、DEM やリモートセンシング画像のように、画素 (pixel) の値が連続値となっているデータのことである。例えば DEM の画素値は標高値であり、空間的に連続な値である。空間的連続性を持つ DEM は、ある画素 i の画素値が z_i であり、画素 i に程近い別の画素 j の画素値が z_j だったとき、画素 i と画素 j の中間に位置する画素 k の画素値 $z_k = (z_i + z_j)/2$ であることが期待できる。すなわち内挿が可能なデータである (2.4 節参照)。連続型データは、画素値の大きさ自体に意味があるデータとも言える。標高値である DEM は、その画素値の大小によってその画素の状態 (つまり標高) が分かる。

主題型データとは、土地利用図や、土壌分類図のような主題図 (thematic map) のことであり、画素値の大小関係は問題とならない。例えば土地利用図で、ある画素が森林であれば、その画素値には 1 が与えられ、都市域であれば 2 が与えられ、水田であれば 3 が与えられたとしよう。都市域の 2 という値は、森林の 1 と水田の 3 の平均値であるが、都市域は、森林と水田の中間の土地利用であったり、森林と水田が混在した領域を都市域と呼ぶわけではない。主題型データにおける画素値は名目上 (nominal) のものであり、その値の大きさ事態に意味はない。

また、ラスター型空間情報は、その画素値が、画素の中心を含む周辺領域の情報をもつか、画素の中心点のみの情報をもつかによって分類される。前者の例としては、土地利用図やリモートセンシング画像があり、後者の例としては、DEM がある。土地利用図は、ある画素の領域内 (例えば $d \times d$) でもっとも面積の広い (占有率の高い) 土地利用をその画素の土地利用とすることが多い。リモートセンシング画像は、地表の $d \times d$ の領域から照射




Figure 2.1 Illustration of a degradation using the thinning-out method.

される電磁波をセンサーがキャッチし、換算式によって整数値に変換したものを画素値としている。これらとは異なり、DEMは、 $d \times d$ の中心点の標高値を画素値としている。例えば、数値地図50 mメッシュ(標高)は、1/25,000の地形図において緯線・経線に沿って200本づつ引いたグリッドラインの交点(グリッド交点, グリッドポイント)の標高値をグリッド交点の周囲の等高線から読みとったものである。AMeDASデータは、日本全国の気象観測所で観測した気温や湿度などのデータであり、ベクターデータである。しかし、ニュース等で見られるAMeDAS画像は、ベクターAMeDASデータをラスター形式に再配置したもので、DEMと同様に画素の中心点のみの情報をもつラスター型空間情報の一例と言えるだろう。

ラスター型空間情報のスケールアップに用いるアルゴリズムは、以上の2種の分類の何れにその空間情報が分類されるかを判断したのち選択されねばならない。

2.2 データを間引く方法

n 画素間隔で画素を選択していき、残りの画素を間引くことで低分解能画像を生成する手法である。Figure 2.1(a)において、白丸のグリッド交点を選択された画素で、黒丸のグリッド交点が間引かれる画素とすると、生成される画像は、Figure 2.1(b)のようになる。例えば分解能5 mの画像からは、2画素間隔で選択していくことで分解能10 mの画像を生成することができる。この手法は最も単純で計算時間も早い。しかし、元となる画像の分解能に依存し、分解能5 mの画像からは、分解能10 m, 15 mといった元画像の分解能の整数倍の分解能をもつ画像でなければ生成できない。この手法は、画素の中心点のみの情報をもつラスター型空間情報に対して用いられる。




Figure 2.2 Illustration of a bi-linear interpolation.

2.3 算術平均による方法

近接する $n \times n$ の画素の値を算術平均する手法である。例えば分解能5 mの画像からは、 2×2 、計4画素の画素値を算術平均することで分解能10 mの画像を生成することができる。この手法は前節の手法と同様に単純で計算時間も早い。しかし、また前節の手法と同様に、元画像の分解能の整数倍の分解能をもつ画像でなければ生成できない。この手法は、連続型の空間情報に対して用いられる。

2.4 内挿法を用いたアルゴリズム

共1次内挿法(bi-linear interpolation)や3次たみ込み内挿法(cubic convolution interpolation)などの内挿手法¹⁾を用いて低分解能の画像を生成する手法である。

例えば、共1次内挿法は、Figure 2.2に示すように、4つのグリッド交点の内側の任意の点において、4点の値を用いて(2.1式)、(2.2)式で内挿する。ただし $[\]$ はガウス記号で、整数部分をとることを示す。

$$P = \{(i+1)-u\}\{(j+1)-v\}P_{ij} + \{(i+1)-u\}\{v-j\}P_{ij+1} + \{u-i\}\{(j+1)-v\}P_{i+1j} + \{u-i\}\{v-j\}P_{i+1j+1} \quad (2.1)$$

$$\begin{cases} i = [u] \\ j = [v] \end{cases} \quad (2.2)$$

これを応用して、Figure 2.3において、左側の分解能 d_1 の高分解能空間情報(Figure 2.3(a))から右側の分解能 d_2 の低分解能空間情報(Figure 2.3(b))を生成するとき、例えば、Figure 2.3(b)のグリッド交点番号(1)の値は、Figure 2.3(a)のグリッド交点番号(1), (2), (7),




Figure 2.3 Illustration of a degradation using interpolation.

(8) を用いて生成する。生成する空間情報の分解能が変わっても、同様に低分解能空間情報のグリッド交点の周囲4点の値を用いて低分解能画像を生成することができる。

内挿法を用いたアルゴリズムは、任意の画素サイズの画像が生成でき、画素の中心点のみの情報をもつラスター型空間情報に対して用いられる。内挿法の中でも、共1次内挿法や3次たみ込み内挿法などを用いた手法は、連続型のラスター型空間情報に対して用いられる。一方、最近隣法 (nearest neighbor interpolation) を用いたアルゴリズムは、連続型、主題型の両方のタイプのラスター型空間情報に対して用いられる。

2.5 MTF を応用した低分解能化アルゴリズム

前節の内挿法を用いたアルゴリズムでは、任意の画素サイズの画像が生成できるが、次の理由で、リモートセンシング画像等の画素の中心点周辺の領域の情報をもつラスター型空間情報に対しては用いることができない。

分解能 d_1 をもつリモートセンシング画像 $i_1(x, y)$ の画素の値は、地表面の座標 (x, y) の周囲 $d_1 \times d_1$ の領域から得られた情報で構成されていると考えられる。言い換えると、関数 $i_1(x, y)$ は座標 (x, y) の周囲 $d_1 \times d_1$ の領域の情報を平均化した値の関数といえる。また、内挿法は、ある関数 $i(x)$ (x は連続値) を d_1 という間隔によってサンプリングしたデータ列 (Figure 2.4(a) の左図, $i_1(x)$; x は離散値) から元の関数 $i(x)$ を推定し、サンプリング間隔を d_2 に変えて値を出力し新たなデータ列 (Figure 2.4(a) の右図, $i_2(x)$; x は離散値) を得る手法である。そのため、データ列 $i_1(x)$ の各値がリモートセンシング画像のように位置 x の周囲 d_1 (x を含む $[(n-1)d_1, nd_1]$ の範囲) という領域からの情報を元にした数値、例えば Figure 2.4(b) の左図のように d_1 という領域の平均値である場合、そのデータ列 $i_1(x)$ から推定される元の関数 $i(x)$ (x は連続値) は、 x の周囲 d_1 (x を中心とする $[x-d_1/2, x+d_1/2]$ の範囲) の平均値である。よってこのようにして得られる関数 $i(x)$ (x は連続値) をサンプリング間隔 d_2 でリサンプリングすると、得られるデータ列 $i_2(x)$ (x は離散値、データ間隔 d_2) は、Figure 2.4(b) の右図のように x の周囲 d_1 (x を中心とする $[x-d_1/2, x+d_1/2]$ の

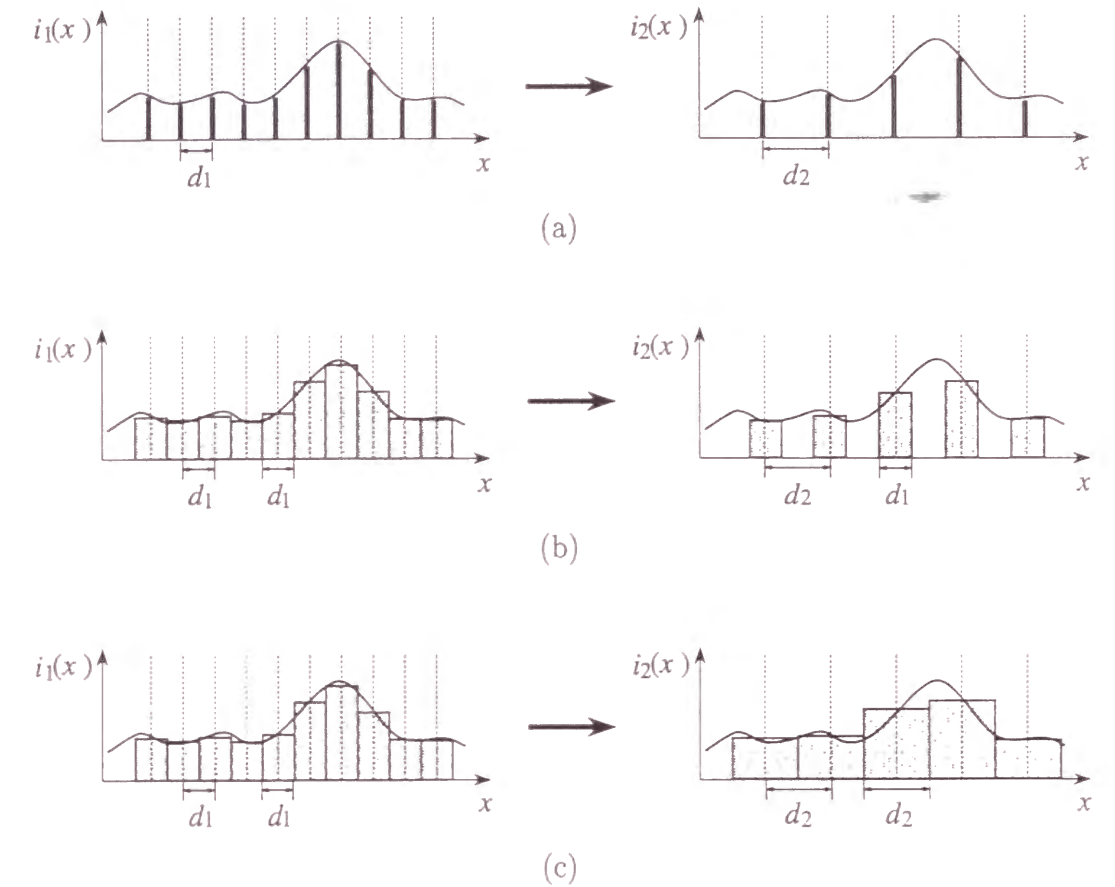


Figure 2.4 Various resampling methods for one-dimensional case.

範囲) の平均値となる。

つまり、分解能 d_1 のリモートセンシング画像 $i_1(x, y)$ を内挿法によって分解能 d_2 に低分解能化すると、得られる低分解能画像 $i_2(x, y)$ は、画素サイズ (すなわちサンプリング間隔) は $d_2 \times d_2$ であるが、画素値は地表面の座標 (x, y) の $d_2 \times d_2$ の領域すべてではなく、その画素の中心部の $d_1 \times d_1$ の領域から得られた情報を基にした画像となる。

高分解能センサー (分解能 d_1) で観測された画像を低分解能化 (分解能 d_2) するには、Figure 2.4(c) のようにリサンプリング間隔 d_2 のすべての領域から得られた情報を基にすべきである。このような真の意味での低分解能化を行うには、以下のようなアルゴリズムで低分解能化を行う必要がある。

リモートセンサーで点光源を撮影したとすると、得られる画像はある広がりをもつ像となる。この広がり方を点像分布関数 (point spread function) と呼ぶ。センサーで観測する被写体を点光源の集まりと考え、リモートセンシング画像 $i(x, y)$ は、地表面の状態を表す関数 $g(x, y)$ と点像分布関数 $p(x, y)$ のコンボリューションと考えられる。

$$i(x, y) = g(x, y) * p(x, y) \quad (2.3)$$

ここで*は、以下のような式で表されるコンボリューションの演算子である。

$$a(x) * b(x) = \int_{-\infty}^{\infty} a(\tau) b(x - \tau) d\tau \quad (2.4)$$

$i(x, y)$, $g(x, y)$, $p(x, y)$ のフーリエ変換をそれぞれ $I(f_x, f_y)$, $G(f_x, f_y)$, $P(f_x, f_y)$ とすると, 2.3式は次式のように変換される. ここで f_x , f_y はそれぞれ, x 方向, y 方向の空間周波数である.

$$I(f_x, f_y) = G(f_x, f_y) \times P(f_x, f_y) \quad (2.5)$$

この点像分布関数のフーリエ変換は, 一般には複素関数で OTF (Optical Transfer Function) と呼び, その絶対値を MTF (Modulation Transfer Function) と呼ぶ. (2.5) 式から, $g(x, y)$ のフーリエ変換 $G(f_x, f_y)$ は次のように簡単に表現できる.

$$G(f_x, f_y) = I(f_x, f_y) / P(f_x, f_y) \quad (2.6)$$

このような手法でリモートセンシング画像から地表面の真の状態を復元する手法を MTF 補正と呼ぶ.

この MTF 補正の方法を利用して, ある分解能 d_1 とそれと異なる分解能 d_2 の $P(f_x, f_y)$ をそれぞれ $P_1(f_x, f_y)$, $P_2(f_x, f_y)$ とし, 分解能 d_1 の $I(f_x, f_y)$ を $I_1(f_x, f_y)$ とすると,

$$I_2(f_x, f_y) = I_1(f_x, f_y) \times \frac{P_2(f_x, f_y)}{P_1(f_x, f_y)} \quad (2.7)$$

で得られる $I_2(f_x, f_y)$ を逆フーリエ変換することにより, 分解能 d_2 のリモートセンシング画像 $i_2(x, y)$ が得られる. 点像分布関数 $p(x, y)$ は, そのセンサーの分解能, 電気的性質, 大気の影響等に依存するのであるが, 最も影響が大きいセンサーの分解能だけを考慮すると, 以下のような簡単な式で近似可能である²⁾. ここでは簡単化のために1次元で考えると, 点像分布関数 $p(x)$ は次式で表現できる.

$$p(x) = \begin{cases} 0 & (x < -\frac{d}{2}, \frac{d}{2} < x) \\ \frac{1}{d} & (-\frac{d}{2} \leq x \leq \frac{d}{2}) \end{cases} \quad (2.8)$$

ここで d は分解能である. 2.8式をフーリエ変換すると次式のように表現される.

$$\begin{aligned} P(f_x) &= \int_{-\infty}^{\infty} p(x) e^{-i2\pi f_x x} dx \\ &= \frac{1}{d} \int_{-\frac{d}{2}}^{\frac{d}{2}} e^{-i2\pi f_x x} dx \\ &= \frac{\sin(\pi f_x d)}{\pi f_x d} \end{aligned} \quad (2.9)$$




Figure 2.5 Illustration of a degradation using a majority rule.

本研究では, 実際の計算は, N 個のデータ列を N 個の周波数域のデータ列にフーリエ変換し, N 個の周波数域のデータ列から N 個のデータ列に逆フーリエ変換する FFT プログラム³⁾を使用した. そのため, (2.7) 式で計算される $I_2(f_x, f_y)$ の逆フーリエ変換で得られる画像 $i_2(x, y)$ は, 1つの画素のサイズが元画像 $i_1(x, y)$ と同じ $d_1 \times d_1$ (すなわち, リサンプリング間隔 d_1) で, 1画素の値が地表面の $d_2 \times d_2$ の領域からの情報を基にした画像となっている. よって, この画像 $i_2(x, y)$ をリサンプリング間隔 d_2 で内挿することによって, 1つの画素のサイズが d_2 で, 地表面の $d_2 \times d_2$ の領域の元の情報全て用いた値をもつ画素からなるリモートセンシング画像が得られる⁴⁾.

2.6 最大頻度に基づく方法

Figure 2.5のように, $d_2 \times d_2$ の領域内で, 最も占有率の高い画素値を選択する手法である. この手法は, 主題型かつ画素の中心点周辺の領域の情報をもつラスター型空間情報に対して用いられる.

2.7 結語

本章ではラスター型空間情報のスケールアップの手法について論じた. ラスター型空間情報のスケールアップを行うには, そのラスター型データの種別に応じたアルゴリズムを用いる必要がある. 水文解析によく用いられるラスター型データには, リモートセンシング画像, DEM, 土地利用図, 土壌分類図等が挙げられる. リモートセンシング画像のスケールアップには MTF を応用したアルゴリズム, DEM に対しては, 内挿法を用いたアルゴリズムが適当である. ただし, 生成される疑似画像の分解能が元の画像の整数倍であるという制限に問題がない場合は, MTF を応用したアルゴリズムの代わりに算術平均を用いた方法, 内挿法を用いたアルゴリズムの代わりにデータを間引く方法を用いた方が処理が速いためよい.

また，土地利用図，土壤分類図などの主題図には，最大頻度に基づく方法が適当である。

参考文献

- 1) 高木幹雄・下田陽久 監修: 画像解析ハンドブック，東京大学出版会，1991.
- 2) 宇宙開発事業団 地球観測センター 編集: 地球観測データ利用ハンドブックーランドサット編・改訂版，リモートセンシング技術センター，pp. 6-11-6-12，1990.
- 3) Press, W. H., B. P. Flannery, S. A. Teukolsky and W. T. Vetterling: Numerical Recipes in C, Cambridge University Press, 1988. (丹慶勝市，奥村晴彦，佐藤俊郎，小林誠訳: Numerical Recipes in C [日本語版]，技術評論社，1993.)
- 4) Justice, C. O., B. L. Markham, J. R. G. Townshend and R. L. Kennard: Spatial degradation of satellite data, International Journal of Remote Sensing, Vol. 10, No. 9, pp. 1539-1561, 1989.

第 3 章

リモートセンシング画像の分解能が土地被覆分類精度に及ぼす影響

3.1 概説

水文解析へのリモートセンシングデータの応用方法の代表的なものの一つに，リモートセンシング画像を分類することによって地表面の状態を知ろうとする手法が挙げられる．その領域が，都市域であるか森林域であるかによって，雨水の浸透特性や蒸発散の特性，引いては流出特性などが変わってくるからである．

リモートセンシング画像の空間分解能と分類精度の関係について検討したものに竹内・富田¹⁾，張ら²⁾の研究がある．竹内・富田は，観測年度のそれぞれ異なる航空機 MSS 画像 (1982 年 5 月 23 日; 分解能 5 m)，SPOT/HRV 画像 (1986 年 4 月 7 日; 分解能 20m)，Landsat/TM および MSS 画像 (1987 年 5 月 21 日; 30 m および 80 m) の比較と，分解能 5 m の航空機 MSS 画像から算術平均によって生成した分解能 10 m，20 m，30 m，50 m，80 m の疑似リモートセンシング画像の比較を行っている．張らは，TM 画像 (1984 年 11 月 4 日) から算術平均によって生成した分解能 25 m，50 m，75 m の疑似リモートセンシング画像と SPOT 画像 (1986 年 6 月 9 日) を比較した．しかし，いずれも取得年が異なるリモートセンシング画像を用いて比較しており，疑似リモートセンシング画像も算術平均で生成し，細かく分解能が変化する際の分類精度の変化を見てはいない．

現在利用可能な高分解能リモートセンシング画像には，分解能 30 m の Landsat/TM 画像，80 m の MSS 画像，20 m の SPOT/HRV 画像，50 m の MOS-1b/MESSR 画像など様々なものがある．筆者はこれまでに，これら，異なるセンサーから得られたリモートセンシング画像の分類画像を比較することによって，空間分解能と分類精度との関係について検討を行った³⁾．しかし，異なるセンサーから得られた画像を比較する場合には，波長帯や観測時間の違いや微妙な位置誤差によって分類精度が影響を受け，分解能の違いのみによる精度比較はしにくいと思われる．

そこで本章では，任意に分解能を決定できる低分解能化アルゴリズムを用いて，航空機 MSS 画像から任意の分解能をもつ疑似リモートセンシング画像を生成し，リモートセンシ

Table 3.1 Observed remote sensing images during the Yada river aircraft observation experiment

Landsat-5/TM image	(spatial resolution: 30×30 m, date: 10/23 9:45)
SPOT-2/HRV image	(20×20 m, 10/22 10:27)
JERS-1/OPS image	(18×24 m, 10/28 10:30)
Airborne MSS image	(6.25×6.25 m, 10/18 11:38-11:41)
Aerial photographs	(1:10,000, 10/27)

ング画像の空間分解能と土地被覆分類精度の関係を明らかにする.

3.2 対象流域と使用空間情報

1992 年 10 月に行われた矢田川航空機実験⁴⁾⁵⁾において Table 3.1 のようリモートセンシングデータ取得された. 本研究ではこのとき取得されたこれらのリモートセンシングデータを主に解析に用いている.

Table 3.1 の 4 つのリモートセンシング画像 (Landsat-5/TM, SPOT-2/HRV, JERS-1/OPS, 航空機 MSS) 及び 1996 年 8 月に打ち上げられた ADEOS の高分解能センサー AVNIR のもっている波長帯は, Figure 3.1 の通りである.

本章では, Table 3.1 にあげた画像データのうち, 航空機 MSS 画像と航空写真を用いる. 対象地域は, 愛知県矢田川流域の長久手町, 長久手東小学校周辺の約 3 km 四方の領域とした. 航空写真を基に, 細密数値情報⁶⁾の 10 m グリッドの土地利用マップ (TDT-112) と現地踏査で得られた情報を参考に, 2 m グリッドの領域全体のランドトゥールスマップを生成した (Plate 3.1 参照). 分類クラスは, 森林 (Forest), 水田 (Paddy), 草地 (Grass), 裸地 (Bare soil), 都市域 (Urban), 水域 (Water) の 6 つとした. 河川は水面のほかに, 砂州, 河川敷の裸地, 雑草など異なる土地被覆を含むので, 河川というクラスは設定せず分類対象外とする.

3.3 定量的分類精度評価手法

分類精度は判別効率表 (confusion matrix または error matrix) を用いて定量的評価する⁷⁾⁸⁾. 判別効率表とは, 分類の結果得られた分類クラスと, 実際の地上の状態 (ランドトゥールース) を示す参照クラスをそれぞれ行と列にとった正方の表で, 各成分は分類された画素数である. Table 3.2 に判別効率表の一般例を示す. Table 3.2 において, 分類クラス数は m , 行列の対角成分 $(x_{11}, x_{22} \dots x_{ii} \dots x_{mm})$ が正しく分類された画素数で, それ以外の成分は誤分類された画素数を表現する.

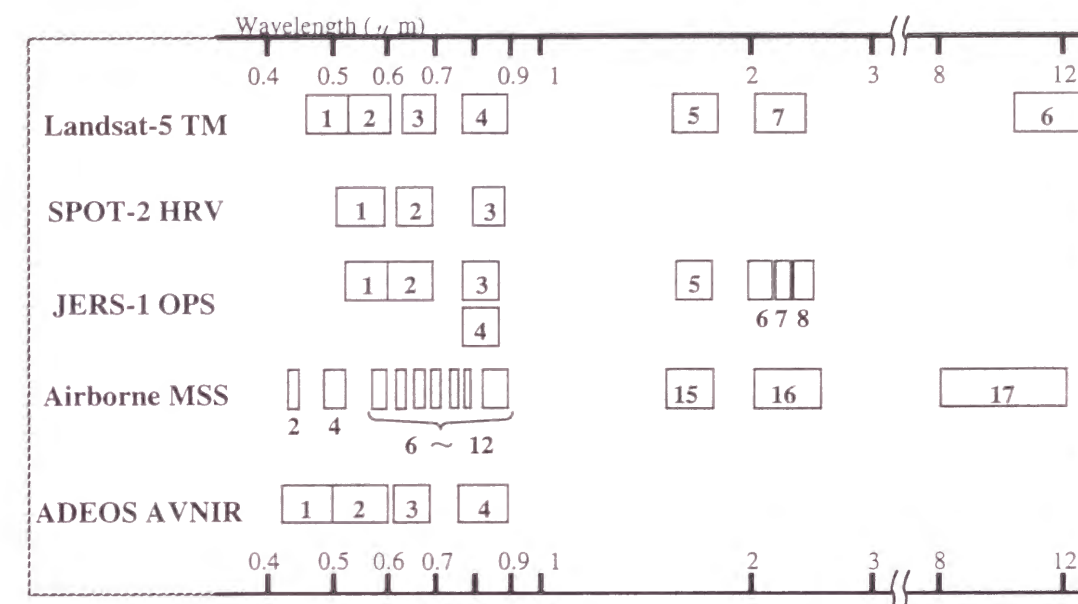


Figure 3.1 Comparison of wavelengths of five sensors.

Table 3.2 Illustration of confusion matrix

Classified Data	Reference Data						Total	UA
	Class 1	Class 2	...	Class i	...	Class m		
Class 1	x_{11}	x_{12}	...	x_{1i}	...	x_{1m}	x_{1+}	UA_1
Class 2	x_{21}	x_{22}	...	x_{2i}	...	x_{2m}	x_{2+}	UA_2
⋮	⋮	⋮	⋱	⋮	⋱	⋮	⋮	⋮
Class i	x_{i1}	x_{i2}	...	x_{ii}	...	x_{im}	x_{i+}	UA_i
⋮	⋮	⋮	⋱	⋮	⋱	⋮	⋮	⋮
Class m	x_{m1}	x_{m2}	...	x_{mi}	...	x_{mm}	x_{m+}	UA_m
Total	x_{+1}	x_{+2}	...	x_{+i}	...	x_{+m}	N	
PA	PA_1	PA_2	...	PA_i	...	PA_m		

Table 3.3 Example of confusion matrix

Classified Data	Reference Data						Total	UA(%)
	Forest	Paddy	Green	Bare soil	Urban	Water		
Forest	913	0	10	0	0	3	926	98.6
Paddy	0	411	3	5	32	3	454	90.5
Green	0	29	318	0	9	10	366	86.9
Bare soil	0	4	0	160	113	0	277	57.8
Urban	0	25	0	5	354	2	386	91.7
Water	3	4	0	3	34	153	197	77.7
Total	916	473	331	173	542	171	2606	
PA(%)	99.7	86.9	96.1	92.5	65.3	89.5		

Table 3.3は判別効率表の一例である。この表からはグランドトゥールースが森林で、かつ正しく森林に分類された画素数は913個、グランドトゥールースが森林でかつ誤って水域に分類された画素数は3個であることが判る。

この判別効率表から様々な精度評価指標が導き出される。総合精度 (overall accuracy: OA) は全画素の何割が正しく分類されたかを示す精度評価指標であり、Table 3.2のように、判別効率表内の総画素数を N 、判別効率表の (i, j) 成分を x_{ij} 、分類クラス数を m としたとき以下の式で表される。

$$OA = \frac{1}{N} \sum_{i=1}^m x_{ii} \quad (3.1)$$

作成者精度 (producer's accuracy; PA) は、グランドトゥールースの何割が正しく分類されているかを示す精度評価指標で、使用者精度 (user's accuracy; UA) は、分類結果の何割が正しいかを示す指標でありそれぞれ以下の式で表現する。

$$PA_i = \frac{1}{x_{+i}} x_{ii} \quad (3.2)$$

$$UA_i = \frac{1}{x_{i+}} x_{ii} \quad (3.3)$$

ここで、 x_{+i} は参照クラスの総ピクセル数、すなわち i 列の要素の合計、 x_{i+} は i 行の要素の合計である。

kappa 係数 (kappa coefficient; KC) は、総合精度から分類が偶然的中する率を除いた精

度評価指標⁹⁾で、上で用いた x_{+i} と x_{i+} を用いて以下のような式で表現される⁷⁾。

$$KC = \frac{N \sum_{i=1}^m x_{ii} - \sum_{i=1}^m (x_{i+} \times x_{+i})}{N^2 - \sum_{i=1}^m (x_{i+} \times x_{+i})} \quad (3.4)$$

日本では、定量的分類精度評価指標として OA がよく用いられる。また、各分類クラスごとの精度評価指標としては PA に相当する指標がよく用いられる⁸⁾。

判別効率表による精度評価では、均質なクラスを持ついくつかの部分領域を精度評価のために全体画像から抽出し、この領域に含まれるサンプルデータに対して分類精度を推定することが一般的である。しかし、実際には、異なるクラスの境界において誤分類が多く発生すると推察されるため、サンプルデータを用いた評価では、分類結果の真の分類精度を評価しているとは言えない。また、空間分解能と分類精度との関係を調べる際には、分解能が粗くなり、複数のクラスが混在する画素 (ミクセル) が多くなることによる影響が大きいものと思われる。ミクセルもまた、異なるクラスの境界において多く発生する。よって、本章の目的に対しては、対象領域すなわち画像全体のグランドトゥールースが必要である。しかし、画像全体のグランドトゥールースを用いた定量的分類精度評価は、東海大学情報技術センターで作成された土地被覆分類用標準データセットを用いて行われた例¹⁰⁾¹¹⁾があるが、それ以外のサイトではあまり行われていない。本章では、航空写真を元に作成した、画像全体のグランドトゥールースマップ (Plate 3.1) を用いる。

このグランドトゥールースマップは2 m という高分解能のものである。従来の同様の研究²⁾では、例えば分解能20 mの画像と30 mの画像の分類精度を比較するとき、高分解能のグランドトゥールースマップから最大頻度によって20 mと30 mグリッドのグランドトゥールースマップを生成し、それぞれの分解能のグランドトゥールースを用いて分類精度を評価していた。それに対して本章では、高分解能のグランドトゥールースマップをそのまま用いて、同一の基準で分類精度評価を行う。例えば、分解能10 mの画像では、1つの画素に、グランドトゥールースマップの5×5画素が対応するので、グランドトゥールースマップのこの25個の画素のそれぞれにおいて分類の可否を判定する。生成する疑似画像は基画像の6.25 mを除いて、10 m、12 mと2 m毎なので、各疑似画像の1画素内にグランドトゥールースマップの画素がきっちり収まる。

3.4 疑似低分解能画像の発生と分類精度評価

分解能6.25 mの航空機MSS画像を基に、分解能10 m、12 m、14 m、...と2 mごとの分解能の疑似画像を分解能30 mまで3次たため込み内挿法(CC)とMTF補正を応用したアルゴリズム(MTF)を用いて低分解能化を行った。Plate 3.2にとCCとMTFを用いて低分解能化を行った分解能30 mの疑似画像を示す。band 6に青、band 8に緑、band 12に赤を割り当てたフォールスカラー画像である。CCによる低分解能化画像(Plate 3.2(a))は、相対的に不連続な画像となっているのに対し、MTFによる低分解能化画像(Plate 3.2(b))の方は滑らかな画像となっていることが見て取れる。これは、CCによる画像の1つの画素

Table 3.4 Confusion matrix for maximum likelihood classification of an Airborne MSS image (6.25 × 6.25 m)

Classified Data	Reference Data							UA(%)
	Forest	Paddy	Green	Bare soil	Urban	Water	Total	
Forest	833914	22236	81079	12062	28926	4702	982919	84.84
Paddy	24813	117267	48268	12436	39087	765	242636	48.33
Green	71683	54846	169707	11275	35145	1168	343824	49.36
Bare soil	24007	19304	27829	95992	69527	2731	239390	40.10
Urban	83748	45709	73535	35486	304973	3337	546788	55.78
Water	11275	597	2123	363	2704	10293	27355	37.63
Total	1049440	259959	402541	167614	480362	22996	2382912	
PA(%)	79.46	45.11	42.16	57.27	63.49	52.05		

Overall Accuracy = 64.30 %

Kappa Coefficient = 51.05 %

が、30×30 m の領域全体ではなく、元画像の1つの画素と同じ面積、すなわち画素の中心部の6.25×6.25 m の領域のみからの情報を基にしており、隣の画素の情報と不連続になっているためである。

分解能 6.25 m の航空機 MSS 画像及び分解能 10 m～30 m の疑似低分解能画像を、航空機 MSS 画像の 12 の波長帯 (Figure 3.1) を全て用いて最尤分類法¹²⁾⁸⁾ によって分類した。Plate 3.3にその分類画像を示す。ランドトゥールスマップ (Plate 3.1) に比べて、若干都市域に分類された領域が多く見えるが、定性的に見て精度よく分類されているように見える。

Table 3.4に Plate 3.3の分類結果の判別効率表を示す。PA では、草地が最も精度が低く、森林や都市域に誤分類することが多いことが分かる。UA では、都市域と水域が精度が低く、森林と草地を都市域に誤分類したり、森林を水域に誤分類することが多いことが分かる。Plate 3.3の分類結果は、定性的には精度よく分類されていると判断されるが、定量的精度評価指標では、OA が 64.30%、KC が 51.05%程度であった。画像全体のランドトゥールスによって評価した従来の研究²⁾¹³⁾ でもほぼ同程度の OA が報告されており、画像全体のランドトゥールスによる評価した定量的分類精度は KC では 50%強、OA でも 65%程度であれば十分よい分類結果であると言える。

判別効率表における対角成分以外の成分に含まれた画素、すなわち誤分類された画素を灰色に着色した画像を Plate 3.4に示す。この灰色の領域を本研究ではグレーゾーンと呼ぶこととする。Plate 3.4からは、グレーゾーンが異なるクラスの境界上に多く発生していることが分かる。

Table 3.5に CC と MTF による低分解能化画像の最尤分類結果を OA と KC で示す。分解能 6.25 m の画像は同じものなので当然 OA と KC それぞれの値は同じであるが、低分

Table 3.5 Comparison of the maximum likelihood classification accuracies of the 6.25-m airborne MSS image and its degraded images with 10-m to 30-m resolution using cubic convolution interpolation (CC) and MTF algorithm (MTF).

Resolution	CC		MTF	
	OA	KC	OA	KC
6.25 m	64.30	51.05	64.30	51.05
10 m	64.50	51.08	64.58	51.20
12 m	65.18	51.85	65.28	51.98
14 m	64.40	50.91	64.66	51.23
16 m	63.64	50.15	63.80	50.35
18 m	63.33	49.45	63.80	50.09
20 m	63.30	49.43	63.61	49.82
22 m	60.45	45.82	60.80	46.30
24 m	62.57	48.29	62.96	48.86
26 m	62.24	47.94	61.47	47.73
28 m	60.96	46.84	61.37	47.49
30 m	58.49	44.61	59.22	45.58

(unit:%)

解能化した画像は、ほとんどの場合 CC より MTF による画像の方が分類精度が若干良いことがこの表から見て取れる。また、高分解能画像よりも低分解能画像の方が CC と MTF による画像の分類精度の差が大きいことが分る。CC による画像は1画素の値が、画素の中心部の6.25×6.25 m の領域のみから得た情報を基にしていることに対し、MTF による画像は分解能 10 m なら 10×10 m の領域から情報を得ている。そのため、MTF による画像の方が1画素の情報量が多いため、分類精度が良いという結果となる。また、分解能が粗くなるほど1つの画素の情報量の差は大きくなるため、分解能が粗くなるにしたがって CC と MTF による画像の分類精度の差が大きくなっている。

Figure 3.2に算術平均による低分解能化画像の最尤法による分類結果を OA と KC で示す。分解能が粗くなるにつれて、精度が低下することが分るが、算術平均では 6.25 m 毎の大きさの分解能をもつ画像でなければ生成できないので、細かく分解能が変化するときの分類精度の変化を見ることはできない。

Figure 3.3に MTF による低分解能化画像の最尤法による分類結果を示す。一番上の図が OA と KC、真中が PA、一番下が UA の分解能による変化を示している。一番上の図からは、分解能 12 m を最高に分解能が粗くなるにしたがって OA と KC が徐々に悪くなっていくのが分る。また、Table 3.5から、最も低分解能の 30 m の分類精度と比較して、最高の精度をもつ分解能 12 m の分類精度は、OA、KC とともに 6 ポイント程度分類精度が向上




Figure 3.2 Relationship between spatial resolution and maximum likelihood classification accuracy based on the degraded images using the arithmetic mean.

していることが分る。

Figure 3.3の真中と一番下の図、PA と UA に注目すると、分解能が粗くなるにしたがって、森林のPA が下がり、UA が上がるのが目に付く。分解能が粗くなるにしたがってPA が下がる理由については次のように推測できる。森林内はほぼ均一なので分解能が高く(1画素の占める領域が狭く)ても、分解能が低く(1画素の占める領域が広く)広範囲の情報を持っていても分類結果はほぼ正しく森林となる。しかし、森林と他の領域の境界近くでは、分解能が低く広範囲の地表面の情報を画素がもつとき、森林以外の土地被覆の地表面の情報も混ざってしまい誤分類を発生し、PAが悪くなる原因となるのではないだろうか。また、PAとUAの変化はOAとKCに大きな違いがなければ、PAが良ければUAは悪く、UAが良ければPAは悪くなる傾向にある。このためFigure 3.3の森林では、分解能が低くなるにしたがってPAが下がっていく傾向を示すのと逆に、UAは上がっていく傾向を示すものと思われる。森林以外の分類クラスについては、森林のように顕著な傾向を見つけることはできない。森林以外の分類クラスは、森林ほど広範囲に均一な土地被覆で覆われた領域は少ないので、上述のような理由による顕著な傾向は現れないのではないだろうか。

3.5 疑似 TM 画像と疑似 AVNIR 画像の模擬発生と分類・精度評価

MTFによる分解能30mの疑似画像と、Landsat-5/TM画像の分類精度の比較を行った。TM画像は、分解能120mのband 6を除く、band 1, 2, 3, 4, 5, 7を用いた。TM画像のband 1, 2, 3, 4, 5, 7に対応するように、航空機MSS画像のband 4, 6, 8, 12, 15, 16(Figure 3.1参照)を選択し、MTFによって分解能30mの疑似画像を生成した。この2つの画像を最尤法で分類した結果、TM画像は、OAが57.00%、KCが44.60%であった。MTFによる疑似画像の方は、OAが57.82%、KCが44.38%という値であった。OA、KCともに差が1ポイント未満であり、MTF補正を応用したアルゴリズムの妥当性が証明されている。




Figure 3.3 Relationship between spatial resolution and maximum likelihood classification accuracy based on the degraded images using MTF algorithm (the upper panel: OA and KC; the middle: PA; the lower:UA).

次に、ADEOS/AVNIR のもつ band 1, 2, 3, 4 に近い波長帯として、航空機 MSS 画像の band 2, 6, 9, 12(Figure 3.1参照) を選択し、MTF によって分解能 16 m の疑似 AVNIR 画像を生成した。Plate 3.5に疑似 AVNIR 画像のフォールスカラー画像を示す。疑似 TM 画像のフォールスカラー画像とも言える Plate 3.2(b) と比較すると、AVNIR 画像の空間分解能の高さがよく分かる。

この疑似画像も最尤法で分類したところ、OA で 60.25%、KC で 46.09%という値を示した。上述の Landat-5/TM 画像と比較すると、OA で 3 ポイント、KC で 2 ポイント精度が向上した。また、航空機 MSS 画像から生成した疑似 TM 画像と比較すると、OA で 2.4 ポイント、KC で 1.7 ポイント精度が向上した。航空機 MSS 画像から生成した疑似 AVNIR 画像の波長帯は、実際の AVNIR の持っている波長帯とは微妙に異なるが、単純に最尤法を用いた場合、OA で 60%程度、KC で 46%程度の精度を示すことが期待できる。

3.6 結語

本章では、リモートセンシング画像の空間分解能が分類精度に及ぼす影響について検討した。異なるセンサーによって観測された画像では、波長域の違いや位置誤差が原因となって直接精度比較しにくい。そのため、6.25 m の分解能をもつ航空機 MSS 画像から、低分解能化アルゴリズムによって生成した 10 m から 30 m の分解能をもつ疑似リモートセンシング画像の分類精度を比較した。ある 1 つの画像を基にして分解能の異なる画像を生成するため、位置誤差と波長帯の違いのない画像を比較することができる。任意に分解能を決定できる MTF を応用したアルゴリズムを用いたため、2 m 刻みという細かく分解能が変化する際の分類精度の変化を検討できた。Figure 3.3において、総合精度(OA) および kappa 係数(KC) は完全な右下がりの変化は示さなかったが、分解能 12 m において最も精度が高く、分解能が粗くなるにしたがって分類精度は低下していく様子が確認できた。また、最も精度が良かった分解能 12 m の分類精度と分解能 30 m の画像と比較すると OA, KC で約 6 ポイント程度向上することが確認できた。

1996 年 8 月に打上られた ADEOS の AVNIR は、マルチスペクトラルモードで 16 m という分解能を持っている。惜しくも、1997 年 7 月にミッション遂行不可能となってしまう、それ以降新たな画像を撮影することはできなくなってしまった。本章での検討によれば、単純に最尤法を用いた場合、OA で 60 または、同一の条件での TM 画像の分類精度が、OA で 57 従来、高分解能のマルチスペクトラルリモートセンシング画像としてよく用いられてきた Landsat/TM 画像に比べて ADEOS/AVNIR 画像の分類精度は、OA で 3 ポイント、KC で 2 ポイント程度向上することが期待された。

参考文献

- 1) 竹内章司, 富田強: 衛星画像のスペクトル情報と空間情報を併用した市街地の分類, 写真測量とリモートセンシング, Vol. 27, No. 27, pp. 6-15, 1988.

- 2) 張子珏, 河西由美, 福江潔也, 下田陽久, 坂田俊文: 土地被覆分類における LANDAT TM および SPOT HRV データの特性評価, 写真測量とリモートセンシング, 27(3), 4-15, 1988.
- 3) 児島利治: 空間分解能の異なるリモートセンシングデータを用いた土地被覆分類精度の定量的評価, 岐阜大学修士論文, 1995.
- 4) 宝 馨, 立川康人, 近藤昭彦, 西尾邦彦, 芝野博文, 執印康裕, 田中隆文, 小池俊雄, 北田勝紀, 富井直弥: 矢田川航空機実験および同期地上観測実験について, 水文・水資源学会誌, Vol. 6, No. 1, pp. 71-75, 1993.
- 5) 財団法人 リモートセンシング技術センター 鳩山事業部: ADEOS/AVNIR の解像力, 立体視機能等の評価および解析アルゴリズム開発のためのデータ取得実験観測成果報告書, 1993.
- 6) 財団法人 日本地図センター: 数値地図ユーザーズガイド (改訂版), p. 423, 1994.
- 7) Congalton, R. G.: A review of assessing the accuracy of classifications of remotely sensed data, Remote Sensing of Environment, Vol. 37, pp. 35-46, 1991.
- 8) 高木幹雄・下田陽久 監修: 画像解析ハンドブック, 東京大学出版会, 1991.
- 9) Foody, G. M.: Classification accuracy assessment: some alternatives to the kappa coefficient for nominal and ordinal level classification, Remote Sensing from Research to Operation, pp. 529-538, 1992.
- 10) 福江潔也: 土地被覆分類用標準データセット, 社団法人 日本リモートセンシング学会 評価・標準化研究会セミナーノート, 1996.
- 11) 東海大学情報技術センター: 標準データセット (Ver. 5.0b), 1995.
- 12) 藤村貞夫, 豊田弘道, 愛甲敬, 鈴木康志: マルチスペクトル画像を用いて自動識別手法の比較, 計測自動制御学会論文集, Vol. 14, No. 3, pp. 269-276, 1978.
- 13) ドニー・クスハルドノ, 福江潔也, 下田陽久, 坂田俊文: マルチバンド画像を対象とした同時生起行列に基づくニューラルネットワーク土地被覆分類モデルの検討, 日本リモートセンシング学会誌, Vol. 16, No. 1, pp. 36-49, 1996.

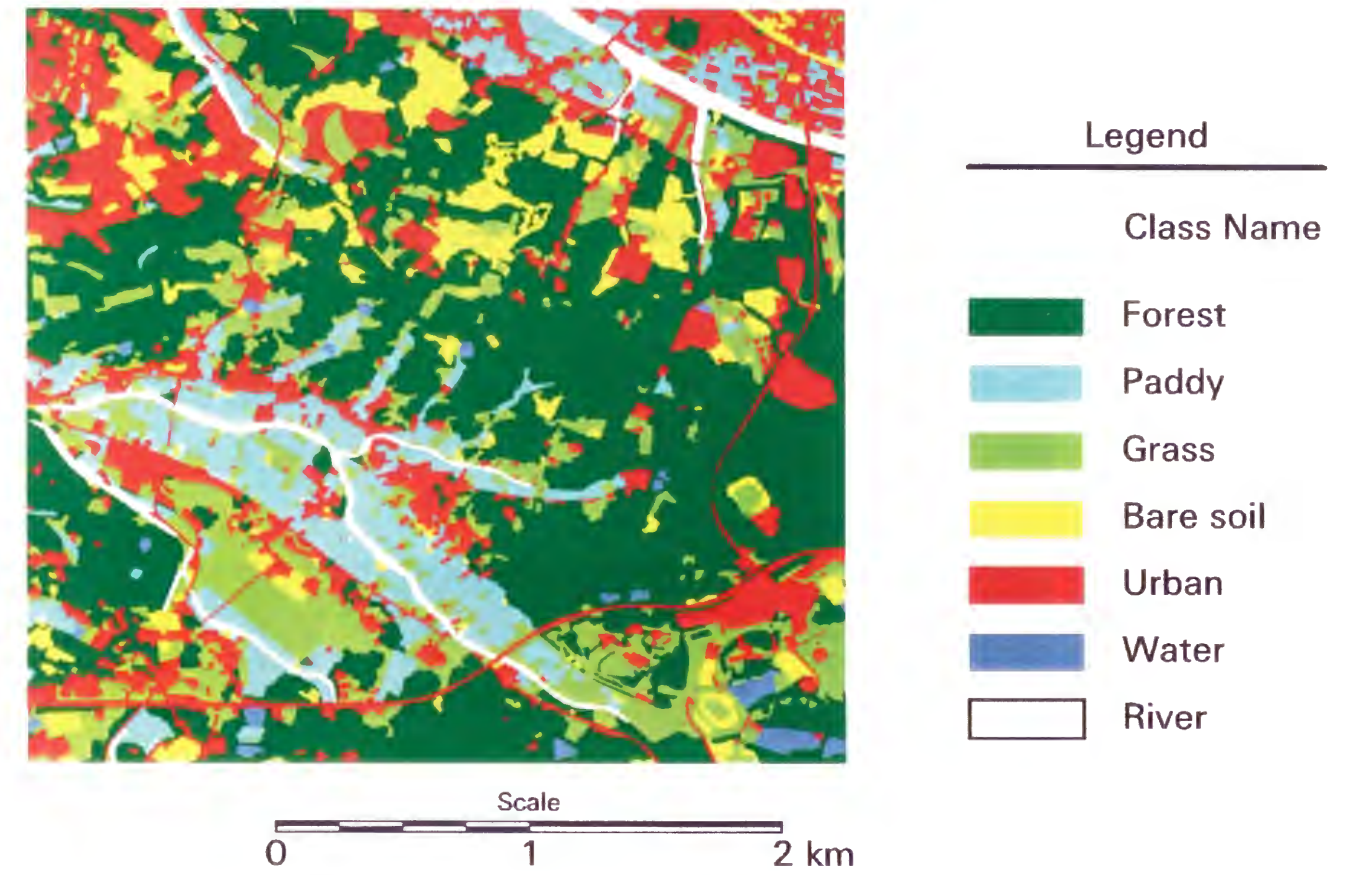




Plate 3.1 Ground truth map of the study area.



(a)



(b)

Plate 3.2 Airborne MSS images simulated to 30×30 m, using (a) CC and (b) MTF; Red: band 12; Green: band 8; Blue: band 6.




Plate 3.3 Maximum likelihood classification using all 12 bands of an Airborne MSS image.




Plate 3.4 Gray zones with maximum likelihood classification using all 12 bands of Airborne MSS image.




Plate 3.5 Simulated ADEOS/AVNIR image.

第 4 章

リモートセンシング画像の分解能が植生指標・蒸発散量推定値に及ぼす影響

4.1 概説

前章では、高分解能リモートセンシング画像を低分解能化していった場合に、土地被覆分類の精度がどのように影響を受けるかといった問題について検討した。本章では、植生指標及びそれに基づく蒸発散推定量に着目し、それらがどのように空間分解能の影響を受けるかについて検討する。

リモートセンシングデータを用いて蒸発散量を推定した近年の研究には、以下のようなものが挙げられる。古藤田ら¹⁾は、Landsat/MSS データを用いて土地被覆分類を行い、土地被覆ごとの気温、アルベード、地中熱流係数を与え、平衡蒸発量型の可能蒸発式を用いて蒸発散量を推定する手法を提案している。Kotoda²⁾や、Hoshi ら³⁾は、この方法をさらに発展させ、DEM による地形をも考慮した改良型 Penman 式による蒸発散量推定手法を提案している。

東北大のグループは、NOAA/AVHRR のデータから求めた NDVI (Normalized Difference Vegetation Index) を基に月蒸発散量を推定している⁴⁾⁵⁾⁶⁾。Seevers and Ottmann⁷⁾は、NDVI と穀物係数 (crop coefficient) を結びつけることによって蒸発散量を推定する手法を提案している。佐渡⁸⁾は、Landsat/TM 画像の NDVI の値を浸透面積率に割り当て、Morton 法を適用して蒸発散量の推定を行い、さらに、佐渡・児島⁹⁾は、Landsat/TM 画像の複数のバンドの DN(後述) を独立変数とする重回帰式によって、月蒸発散量の推定を試みている。

また、近藤昭彦¹⁰⁾¹¹⁾ は、アジア地域を対象として、NOAA-EPA 作成の Global Ecosystem Database に含まれている NDVI の季節変化及び年間積算値と、気候学的方法で求めた月蒸発散量及び年蒸発散量との関係について検討し、さらに、NDVI の季節変化のクラスター分析からモンスーンアジアの植生図を作成して、土地被覆変化による蒸発散量変化についても検討を加えている。

しかし、リモートセンシングデータの空間分解能が解析結果に及ぼす影響についての検討は、あまり行われていないようである。そこで本章では、航空機 MSS 画像 (分解能 6.25m)

および SPOT/HRV 画像 (分解能 20m) とそれに基づく低分解能画像を用いることにより、空間分解能の違いによって、

- 植生指標 (NDVI) がどのように変化するか、
- NDVI に基づく蒸発散量推定値がどのように変化するか

について検討する。

4.2 植生指標について

物体は様々な波長帯 (バンド) の電磁波に対して固有の分光反射特性を持っており、その特性の違いを目的に応じて選択し利用する。植生の場合、可視域の赤バンドの電磁波 (約 $0.4\sim0.7\ \mu\text{m}$) は、植生に含まれるクロロフィルに吸収されやすく反射が少ないのに対し、近赤外の電磁波 (約 $0.7\sim1.3\ \mu\text{m}$) は植生に吸収されず反射が多いという特徴を持っている。

この特性を利用して植生の情報を抽出するめに、赤バンドの反射率と近赤外バンドの反射率を基にした様々な植生指標 (Vegetation Index) が提案されている¹²⁾。最も単純なものは以下の式で表される DVI (Difference Vegetation Index) である。

$$\text{DVI} = \text{NIR} - R \quad (4.1)$$

ここで、 R : 赤バンドの分光反射率, NIR : 近赤外バンドの分光反射率である。

DVI は NIR と R の差をとっただけの指標なので、全ての波長帯にわたって放射輝度の高い日向の領域と放射輝度の低い日陰の領域では、植生量が同じであっても算定される DVI は異なる。これに対して、NDVI は以下のような式で表され、正規化することにより日向、日陰の影響を受けにくい指標である。このため、NDVI は植生指標のなかでも広く使われ、単に植生指標といえば NDVI を指す事が多い。

$$\text{NDVI} = \frac{\text{NIR} - R}{\text{NIR} + R} \quad (4.2)$$

本章でも、植生指標として NDVI を用いることとする。

4.3 対象流域と使用空間情報

愛知県の瀬戸市及び長久手町の $3.2\times6.4\ \text{km}$ (領域 1) と、それを含む $20.5\times41.0\ \text{km}$ (領域 2) の森林、耕作地、市街地等の土地利用が複雑に入り組んだ領域を対象領域とした (Figure 4.1 参照)。

リモートセンシングデータには、1992 年 10 月に実施された矢田川航空機実験¹³⁾において取得された、 $6.25\ \text{m}$ の空間分解能を持つ航空機 MSS 画像 (領域 1) と分解能 $20\ \text{m}$ の SPOT/HRV (XS) 画像 (領域 2) を使用した。この航空機 MSS 画像は、可視・近赤外及び熱赤外域に 12 の波長帯をもっている。本研究では、NDVI を算定するために、 R バンド (赤)、

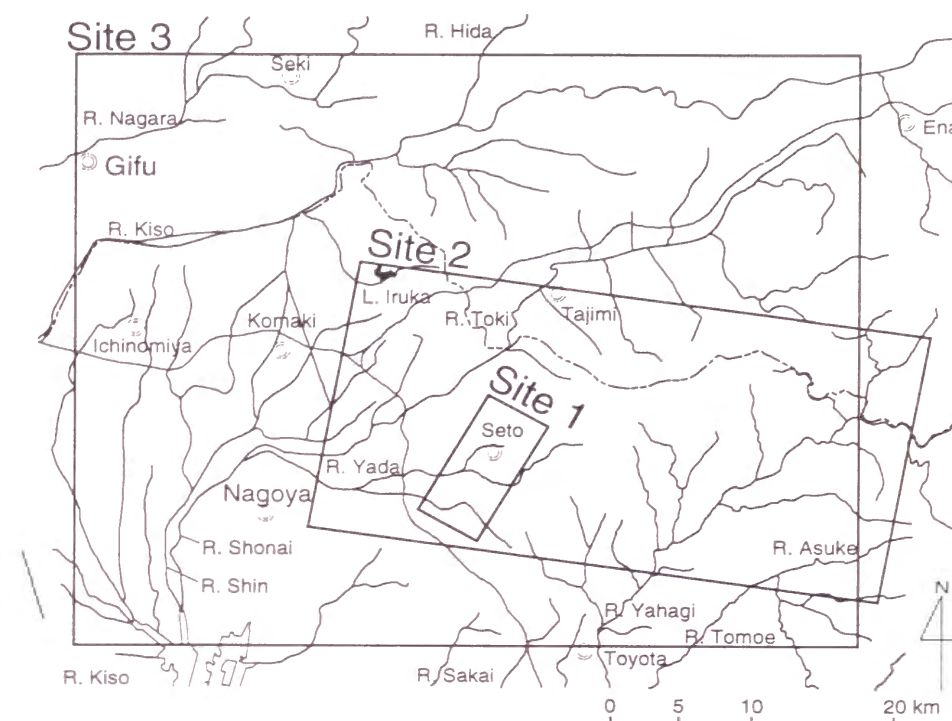


Figure 4.1 Test sites.

NIR バンド (近赤外) として航空機 MSS 画像の Band 8 ($0.570\sim0.592\ \mu\text{m}$) と Band 12 ($0.82\sim0.90\ \mu\text{m}$)、SPOT 画像の Band 2 ($0.61\sim0.68\ \mu\text{m}$) と Band 3 ($0.79\sim0.89\ \mu\text{m}$) を用いた。

画像の低分解能化には、MTF を応用した低分解能化アルゴリズム (2 章参照) を用いる。領域 1 では航空機 MSS 画像を基に、 $16\ \text{m}$, $30\ \text{m}$, $50\ \text{m}$, $80\ \text{m}$, $250\ \text{m}$ の分解能の疑似リモートセンシング画像を、領域 2 では SPOT/HRV 画像を基に、 $30\ \text{m}$, $50\ \text{m}$, $80\ \text{m}$, $250\ \text{m}$, $700\ \text{m}$, $1100\ \text{m}$, $2000\ \text{m}$ の分解能の疑似リモートセンシング画像を生成する。疑似リモートセンシング画像の分解能は、Table 4.1 に示すデータにそれぞれ対応している。

4.4 分光反射率の算定

リモートセンシング画像の各画素の値は、一般的に $0\sim127$ (7bit), $0\sim255$ (8bit), $0\sim16384$ (15bit) などの整数値で表現されている。例えば、Landsat/MSS 画像は 7bit, Landsat/TM 画像は 8bit, JERS-1/SAR 画像は 15bit である。土地被覆分類を行う場合には、この整数値 (デジタルナンバー, DN と呼ばれる) を直接用いても差し支えない。しかしながら、地上の物理量とリモートセンシングデータを関係づける場合には、画像取得の際にセンサーに固有の関数で変換される DN を用いたのでは一般性が損なわれる。このため、本研究では、まず DN から分光輝度に換算し、さらに分光反射率に変換してから (4.2) 式を用いて NDVI を算定する。

Table 4.1 Spatial resolution of various raster data

resolution	raster data
6.25 m	Airborne MSS image
16 m	ADEOS/AVNIR image
20 m	SPOT/HRV(XS) image
30 m	Landsat/TM image
50 m	MOS-1/MESSR image, 50-m grid DEM
80 m	Landsat/MSS image
250 m	ADEOS-II/GLI image, 250-m grid DEM
700 m	ADEOS/OCTS image
1100 m	NOAA/AVHRR image
2000 m	2 km grid land use data for Japan

4.4.1 分光反射率の定義

分光反射率とは、ある波長の電磁波の入射分光放射束に対する反射分光放射束の比である。式で表現すると次のようになる。

$$\rho = \frac{\phi_r}{\phi_i} = \frac{I_r}{I_i}$$
 (4.3)

ここで、 ρ ：分光反射率、 ϕ_i ：入射分光放射束 ($\text{W}\cdot\text{m}^{-1}$)、 ϕ_r ：反射分光放射束 ($\text{W}\cdot\text{m}^{-1}$)、 I_i ：入射分光放射束密度 ($\text{W}\cdot\text{m}^{-2}$)、 I_r ：反射分光放射束密度 ($\text{W}\cdot\text{m}^{-2}$) である。

航空機 MSS、Landsat/TM、SPOT/HRV などのようなパッシブセンサー (受動センサー) では、観測対象物から放射される電磁波の輝度を反射波として観測しており、このときの入射電磁波は日射である。ここで輝度とは、単位立体角に放射する、あるいは単位立体角から放射される放射エネルギーであり、通常 ($\text{W}\cdot\text{m}^{-2}\cdot\text{sr}^{-1}$) と表記する。

立体角とは、平面における弧度を 3 次元に拡張したものであり、「球の中心を頂点とし、その球の半径を 1 辺とする正方形に等しい面積を球の表面上で切り取る立体角」として定義される無次元量である (Figure 4.2 参照)。立体角は SI で sr (steradian, ステラジアン) と表記される。なお全方向の立体角は $4\pi\text{sr}$ となる。

4.4.2 入射分光放射束密度の算定

太陽は有効表面温度が約 5780K であり、黒体とみなしてよい。ここに、黒体とは、あらゆる波長の光を完全に吸収もしくは放射する、放射率 $\epsilon = 1$ の仮想的な物体である。また、太陽の半径に比べて太陽と地球の間の距離は十分に長いため、地球から見た太陽は点と考えてよい。点源としての黒体から発せられる電磁波の分光輝度 L_λ ($\text{W}\cdot\text{m}^{-3}\cdot\text{sr}^{-1}$) は、Planck




Figure 4.2 Illustration of the steradian.

の法則によって次式で表される。

$$L_\lambda = \frac{2hc}{\lambda^5} \frac{1}{e^{\frac{hc}{\lambda kT}} - 1}$$
 (4.4)

ここで、 c ：真空中の光の速さ ($\text{m}\cdot\text{s}^{-1}$)、 h ：Planck 定数 ($\text{J}\cdot\text{s}$)、 k ：Boltzmann 定数 ($\text{J}\cdot\text{K}^{-1}$)、 λ ：波長 (m) 及び T ：絶対温度 (K) である。(4.4) 式を全波長について積分すると、黒体からの輝度 L ($\text{W}\cdot\text{m}^{-2}\cdot\text{sr}^{-1}$) が求められる。

放射が方向性を持たない一様平面を仮定すると、 L ($\text{W}\cdot\text{m}^{-2}\cdot\text{sr}^{-1}$) はあらゆる方向に対して一定となる。これを半球方向に積分すると πL ($\text{W}\cdot\text{m}^{-2}$) となる。定数項を整理すると次式で表される Stefan-Boltzmann の法則が得られる¹⁴⁾。

$$I = \pi L = \sigma T^4$$
 (4.5)

ここで、 I ：黒体表面からの放射束密度 ($\text{W}\cdot\text{m}^{-2}$)、 L ：黒体からの輝度 ($\text{W}\cdot\text{m}^{-2}\cdot\text{sr}^{-1}$)、 σ ：Stefan-Boltzmann 定数 ($\text{W}\cdot\text{m}^{-2}\cdot\text{K}^{-4}$)、 T ：絶対温度 (K) である。したがって、Stefan-Boltzmann 定数を用いて、絶対温度 T の点源の輝度 L は次式で表される。

$$L = \frac{1}{\pi} \sigma T^4$$
 (4.6)

上式から、太陽からの輝度 L_{Sun} は、太陽の有効表面温度 $T_{\text{Sun}} = 5780 \text{ K}$ を用いて、

$$L_{\text{Sun}} = \frac{1}{\pi} \sigma T_{\text{Sun}}^4$$
 (4.7)

であらわされる。

点源である太陽からの輝度 L_{Sun} を全球方向に積分すると、太陽からの放射束密度 I_{Sun} が得られる。

$$I_{\text{Sun}} = 4\pi L_{\text{Sun}} = 4\sigma T_{\text{Sun}}^4$$
 (4.8)

ところで、太陽と地球がその平均距離 (1 天文単位) のとき、大気上端に達する太陽放射の放射束密度 I_{00} を太陽定数という¹⁵⁾。種々の観測により $I_{00} \approx 1.37 \times 10^3 \text{ W} \cdot \text{m}^{-2}$ と得られている¹⁴⁾¹⁶⁾。これは、太陽を中心とする地球断面の立体角 Ω_{Earth} に放射される太陽光の放射束密度である。 I_{00} と I_{Sun} を用いて、 Ω_{Earth} は以下の式で表される。

$$\Omega_{\text{Earth}} = \frac{I_{00}}{I_{\text{Sun}}} \quad (4.9)$$

したがって、地球大気上端に到達する太陽光の分光放射束密度 $I_{\lambda \text{ Sun}}$ は、(4.4) 式で得られる太陽の分光輝度 $L_{\lambda \text{ Sun}}$ と Ω_{Earth} の積として求められる。

$$I_{\lambda \text{ Sun}} = L_{\lambda \text{ Sun}} \cdot \Omega_{\text{Earth}} \quad (4.10)$$

4.4.3 分光放射束密度の補正

水平面日射量の補正

(4.10) 式で導かれる太陽の分光放射束密度は、太陽と地球の間の距離が 1 天文単位のと時のみ成立する。そのため、地球の公転軌道が楕円であることによる補正を行う必要がある。また、地球の自転に伴う太陽高度の変化による補正も必要である。これらを考慮すると、大気上端に入射する水平面日射の分光放射束密度 S_{λ} は次式のようにになる¹⁴⁾¹⁵⁾。

$$S_{\lambda} = I_{\lambda \text{ Sun}} \left(\frac{d_m}{d} \right)^2 \cos \theta \quad (4.11)$$

$$\begin{aligned} \left(\frac{d_m}{d} \right)^2 = & 1.000110 + 0.034221 \cos \theta + 0.001280 \sin \theta \\ & + 0.000719 \cos 2\theta + 0.000077 \sin 2\theta \end{aligned} \quad (4.12)$$

$$\cos \theta = \sin \psi \sin \delta + \cos \psi \cos \delta \cos h \quad (4.13)$$

$$\cos h = -\tan \psi \tan \delta \quad (4.14)$$

$$\sin \delta = 0.398 \sin(4.871 + \eta + 0.033 \sin \eta) \quad (4.15)$$

$$\eta = \frac{2\pi}{365} i \quad (4.16)$$

ここで、 d : 観測時の太陽・地球間の距離、 d_m : 太陽・地球間の平均距離、 θ : 太陽の天頂角、 ψ : 緯度、 δ : 赤緯 (春、秋分点 0 度、夏至で +23.44 度、冬至で -23.44 度)、 h : 時角 (南中時を 0 度としたときの太陽の方向角)、 i : 1 月 1 日を 1 とするときのその日の日数である。

大気補正

航空機や衛星に搭載されるセンサーと地上の対象物との間には、空気や水蒸気が存在し、これらによる電磁波の吸収、散乱のために、大気の正確なプロファイルが得られない現在においては、地上における反射率の正確な絶対値を得ることは不可能である。しかし、リモートセンシングによる観測が行われている波長帯は、大気による電磁波の吸収が少ない「大気の窓」と呼ばれる波長帯であり、大気による電磁波の減衰は少ないと考えられる。そのため、本章では、大気による散乱・吸収に関しては、代表的な散乱である Rayleigh 散乱のみを考慮することにする。これは、分子程度の大きさの粒子による散乱を表すものである。大気上端に入射した日射に対する大気による Rayleigh 散乱は次式で表される¹⁵⁾。

$$dI(\lambda) = I_0(\lambda) \exp(-\alpha(\lambda) \sec \theta) \quad (4.17)$$

$$\alpha(\lambda) = \frac{32\pi^3}{3N\lambda^4} \{n(\lambda) - 1\}^2 H_h \quad (4.18)$$

ここで、 I_0 : 大気上端に入射する日射、 θ : 太陽の天頂角、 $n(\lambda)$: 均質大気の屈折率、 N : 単位体積中の分子数 (Loschmidt 数)、 H_h : 均質大気の厚さである。均質大気とは、本来の地球上の大気を一定密度として扱うための大気であり、通常は $H_h = 8000 \text{ m}$ とされる。均質大気の屈折率は波長によらず一定とした。また、上式は球形の分子を仮定しているが、実際の空気分子は球形ではないので、これによる補正係数を (4.18) 式にかける必要がある。補正係数は、窒素分子で 1.037、酸素分子で 1.067 である。本章では、窒素と酸素の体積比を 79 : 21 とし計算している。

4.4.4 反射分光放射束密度の算定

リモートセンシング画像の各画素値は、前述の通り DN で表現されており、反射率を求めるためには、DN から反射分光放射束密度への変換が必要である。本章で用いたリモートセンシング画像 (航空機 MSS 画像、SPOT/HRV 画像) では以下のような処理を行った。

航空機 MSS 画像では、DN から分光輝度への換算式が定義されている¹⁷⁾。

$$L_{\lambda \text{ AMSS}} = \left(\frac{\frac{DN - E_0}{256} \times 20 - 10}{(\sqrt{2})^{11-G}} + \frac{B}{10} \right) \cdot K \quad (4.19)$$

ここで、 $L_{\lambda \text{ AMSS}}$: 航空機 MSS 画像のバンド平均分光輝度 ($\mu\text{W} \cdot \text{cm}^{-2} \cdot \text{sr}^{-1} \cdot \text{nm}^{-1}$)、 DN : DN (0~255)、 E_0 : オフセットエラー (そのバンド、ゲイン、モードでの値)、 G : 測定時ゲイン (0~11)、 B : 測定時オフセット (0~99)、及び K : 輝度係数 (そのバンド及びモードでの値) である。

ただし、与えられた係数 E_0 および K は、1992 年の航空機 MSS 画像取得時ではなく、その 1 年後にキャリブレーションされた値であった。したがって、この E_0 、 K を用いて求め

られる分光輝度の値を用いると、NDVI が過大評価されることが判った。このため以下のような処理を行った。

1992 年の矢田川航空機実験において、航空機 MSS 画像とほぼ同時期に取得された Landsat/TM 画像 (1992 年 10 月 23 日) を用意する。Landsat/TM 画像は、分光輝度への換算式が公表されており¹⁸⁾、極めて容易に分光輝度が求まる。この Landsat/TM 画像から求められる分光輝度を真値とみなす。

航空機 MSS 画像、Landsat/TM 画像の両者から対応する部分領域をいくつか抽出し、最小 2 乗法を用いて航空機 MSS 画像の分光輝度と Landsat/TM 画像の分光輝度の関係を導き出す。航空機 MSS 画像の DN から分光輝度への換算式、Landsat/TM 画像の DN から分光輝度への換算式は、両者とも線形であることから、航空機 MSS 画像の分光輝度を Landsat/TM 画像に合わせて線形変換する。

SPOT/HRV 画像の DN から分光輝度への換算は、次の換算式を用いる¹⁹⁾。

$$L_{\lambda \text{ SPOT}} = \frac{DN}{a} + b \quad (4.20)$$

ここで、 $L_{\lambda \text{ SPOT}}$: SPOT/HRV 画像のバンド平均分光輝度 ($\text{W} \cdot \text{m}^{-2} \cdot \text{sr}^{-1} \cdot \mu\text{m}^{-1}$)、 DN : DN (0~255)、 a : 絶対補正ゲイン値、 b : 絶対補正オフセット値、である。 a 、 b は画像ごとに異なり、各 SPOT 画像データセットのヘッダーに記録されている。

以上のように地表からの反射分光輝度 $L_{\lambda \text{ Earth}}$ (すなわち $L_{\lambda \text{ AMSS}}$ 及び $L_{\lambda \text{ SPOT}}$) が得られた。地表面からの放射は、もちろん半球方向のみであるから、地表からの反射分光輝度 $L_{\lambda \text{ Earth}}$ ($\text{W} \cdot \text{m}^{-3} \cdot \text{sr}^{-1}$) を半球方向にのみ積分すると、地表面からの分光放射束密度 $I_{\lambda \text{ Earth}}$ ($\text{W} \cdot \text{m}^{-3}$) が得られる。

$$I_{\lambda \text{ Earth}} = \pi L_{\lambda \text{ Earth}} \quad (4.21)$$

以上の手法を用いて、リモートセンシング画像の各画素における反射率を算定した。

4.5 空間分解能が NDVI に及ぼす影響

領域 1 では、6.25 m の分解能をもつ航空機 MSS 画像を基に、MTF を応用した低分解能化アルゴリズムを用いて、16 m、30 m、50 m、80 m、250 m の疑似画像を生成した。Plate 4.6 に対象領域における分解能 6.25 m の航空機 MSS 画像、および 50 m、250 m の疑似画像を示す。分解能が粗くなるにつれ、画像が平滑化される様子が見て取れる。

領域 2 では、20 m の分解能をもつ SPOT/HRV 画像を基に、MTF を応用した低分解能化アルゴリズムを用いて、30 m、50 m、80 m、250 m、700 m、1100 m、2000 m の疑似画像を生成した。Plate 4.7 に対象領域における分解能 20 m の SPOT/HRV 画像、および 250 m、1100 m の疑似画像を示す。領域 2 と同様に、分解能が粗くなるにつれ、画像が平滑化される様子が見て取れる。

4.5 空間分解能が NDVI に及ぼす影響

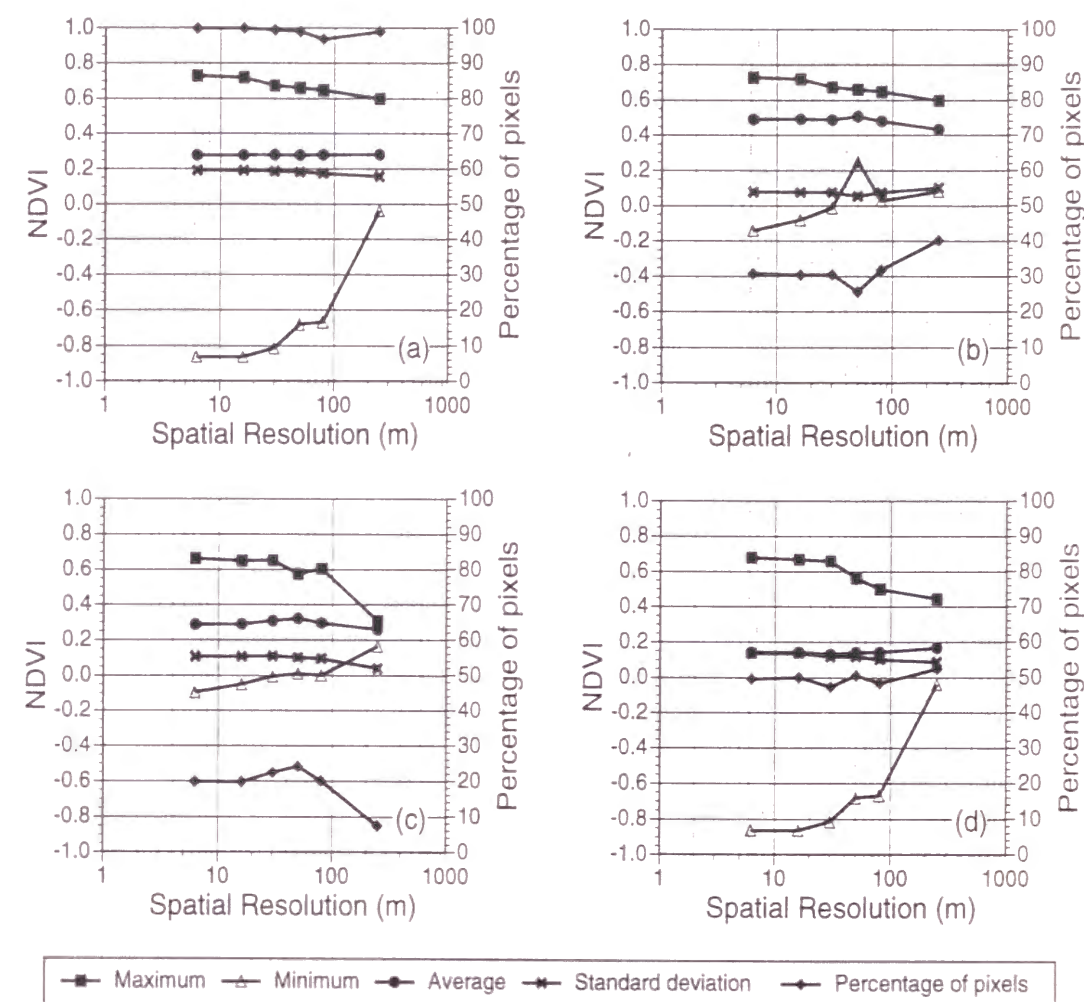


Figure 4.3 Relationship between spatial resolution and NDVI in Site 1.

4.5.1 領域全体の統計量について

領域 1、2 のそれぞれにおいて、各ピクセルの赤バンド、近赤外バンドの反射率から NDVI を算定し、その領域平均、標準偏差、最大値、最小値を求めた。Figure 4.3(a) に領域 1 の領域全体における、分解能ごとのそれらの値を示す。Figure 4.3(a) からは、領域 1 における NDVI の領域平均値は約 0.28 であり、分解能によってほとんど変化しないことが分かる。標準偏差、最大値は分解能が粗くなるにしたがい徐々に小さくなり、最小値は徐々に大きくなる傾向が見られる。

Plate 4.8 に領域 1 における 6.25m、50m、250m の NDVI の分布を示す。分解能が粗くなるにつれ、赤色で示される NDVI が極端に高いピクセルが減少する様子が分かる。

Figure 4.4(a) は領域 2 の領域全体における、分解能ごとのそれらの値を示している。領域 2 では、NDVI の領域平均値は約 0.29 であり、分解能によってほとんど変化しなかった。

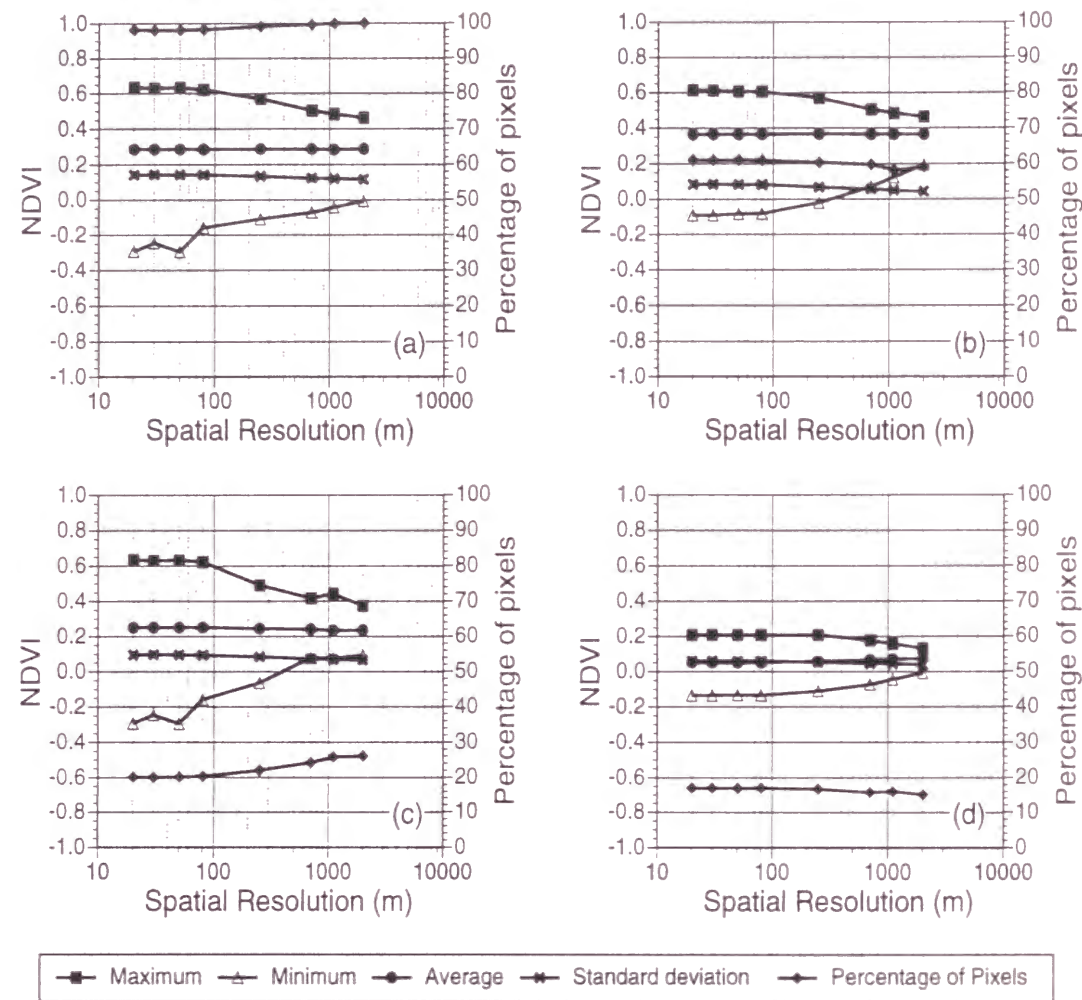


Figure 4.4 Relationship between spatial resolution and NDVI in Site 2.

領域1と同様に、標準偏差、最大値は分解能が粗くなるにしたがい徐々に小さくなり、最小値は徐々に大きくなる傾向が見られる。分解能が同じ画像では、最大値、最小値は領域1と領域2でほぼ同等であった。

Plate 4.9に領域2における20 m, 250 m, 1100 mのNDVIの分布を示す。領域1と同様に、分解能が粗くなるにつれ、赤色で示されるNDVIが極端に高いピクセルが減少する様子が分かる。

4.5.2 土地被覆クラス毎の統計量

航空機 MSS 画像の12バンド全てを用いて、マルチレベルスライス法と最尤法により、領域1を森林、耕作地、都市域、水域の4クラスに分類した。領域2では、SPOT/HRVの3バンド全てを用いて、領域1と同じ4クラス、およびそのクラスにも分類されない

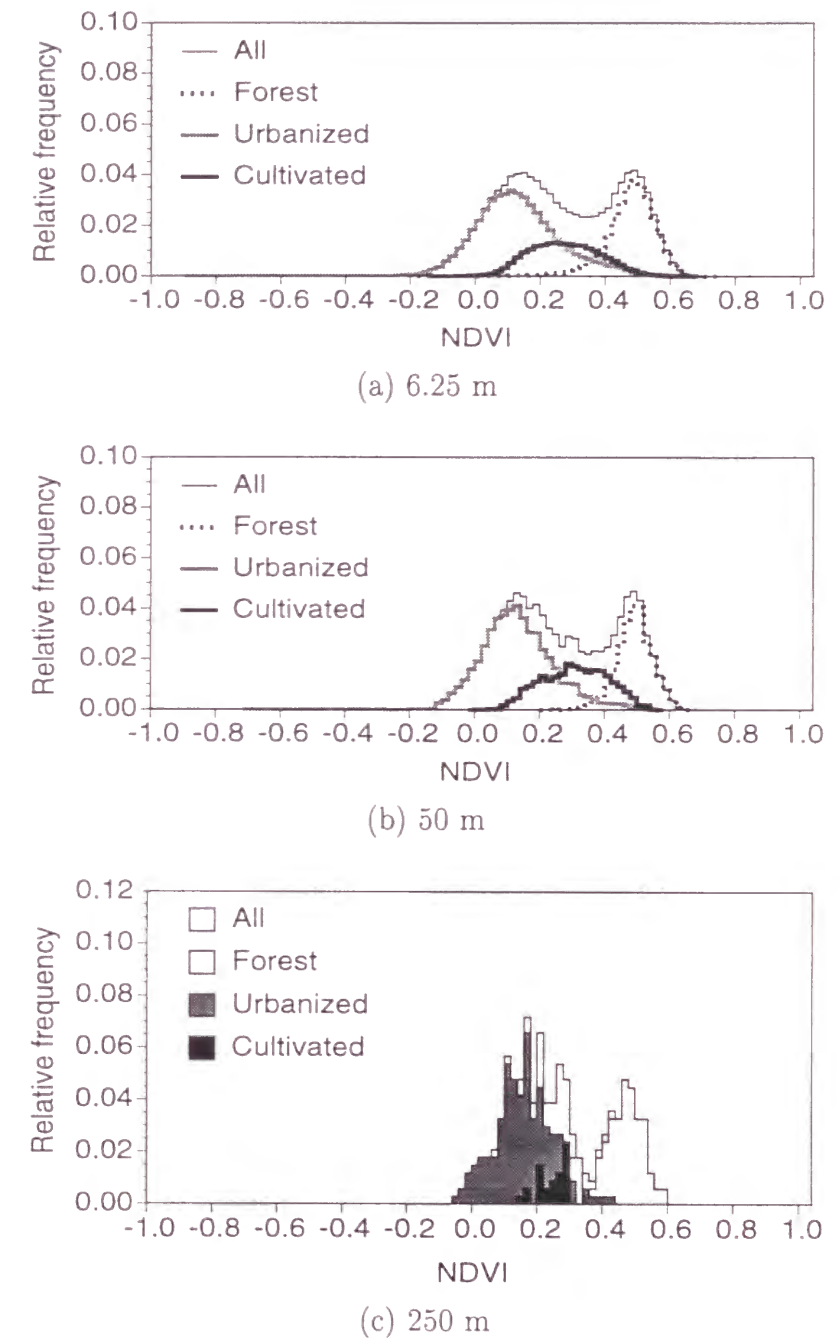


Figure 4.5 Histograms of NDVI in Site 1.

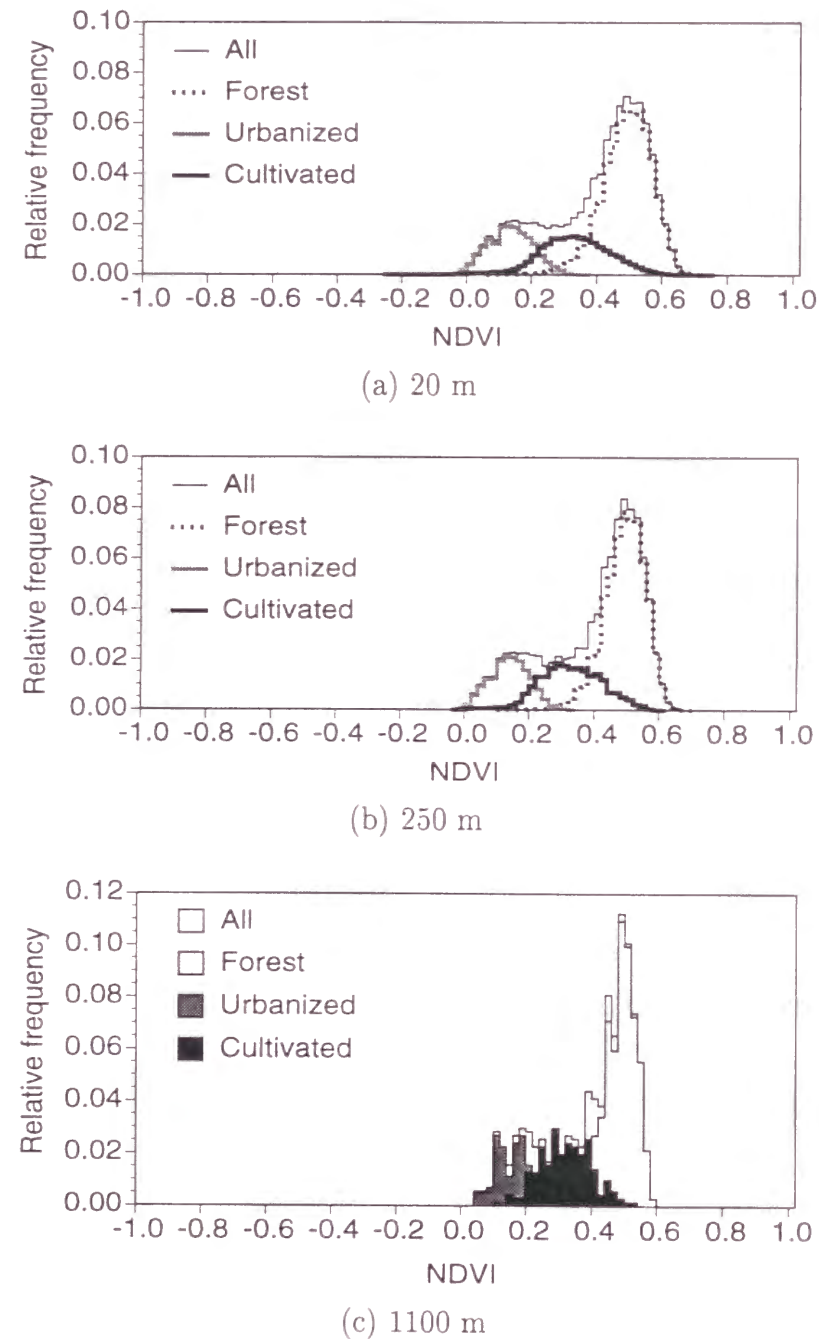


Figure 4.6 Histograms of NDVI in Site 2.

Unknown class に分類した。これらの分類結果を用いて、領域1, 2における森林, 耕作地, 都市域の各クラス毎の NDVI の変化を見た。水域は領域1, 2のいずれにおいても, 全領域の1%に満たないため解析対象から除いた。領域2の Unknown class も解析対象から除いた。

Figure 4.3(b), (c), (d) は, 領域1において, それぞれ森林, 耕作地, 都市域に分類された各領域内の NDVI の分解能による変化を示している。各分類クラスの NDVI の領域平均値は, 領域全体の NDVI と同様に, あまり分解能によって変化しないことが分かる。耕作地と都市域の標準偏差は分解能が粗くなるにつれて小さくなっている。しかし, 森林の標準偏差は分解能 250m で逆に大きくなっている。これは, 80m まで森林と分類されていなかった領域が, 森林と分類されたためである。全領域を森林が占める割合は, 80m まで約 30%程度であったが, 250m では約 40%程度に増加している。また, 森林域の NDVI の最小値は分解能 50m で 0.25 と他と比べて極端に高い。これは, 分解能 50m 以外の画像では森林と分類されている NDVI の低い領域が, 分解能 50m の画像では森林以外に分類され, 分解能 50m の森林域の NDVI の最低値が高くなったことが原因である。

Figure 4.4(b), (c), (d) は, 領域2において, それぞれ森林, 耕作地, 都市域に分類された各領域内の NDVI の分解能による変化を示している。領域1と同様に, 各分類クラスの NDVI の領域平均値は, 分解能によってあまり変化せず, 標準偏差は分解能が粗くなるにつれて小さくなっている。

4.5.3 ヒストグラムによる考察

Figure 4.5 に, 領域1における, 分解能 6.25m, 50m, 250m の画像から算定された NDVI のヒストグラムを, Figure 4.6 に, 領域2における, 分解能 20m, 250m, 1100m の画像から算定された NDVI のヒストグラムを示す。都市域, 森林, 耕作地の各土地被覆ごとに示すとともに, それらの和(領域全体)も併記している。各土地被覆のヒストグラムは重ねてあるため, 森林の最小値の方の裾は見えなくなっている。Figure 4.5(c), Figure 4.6(c) は, 見やすくするためヒストグラムの中を塗りつぶしている。

領域2では森林の割合が大きいため, Figure 4.6の森林の相対頻度は, Figure 4.5よりも高くなっている。Figure 4.5, 4.6からは, 分解能が粗くなるとヒストグラムの定義域(NDVIの最小値と最大値の幅)が狭まり, 相対頻度が高くなることが分かる。都市域, 森林, 耕作地のそれぞれのヒストグラムは, 分布形は左右対称の釣り鐘型で同じだが, 定義域は異なることが確認できる。分解能 6.25m(領域1)では, 都市域のヒストグラムの裾が NDVI が負の値の方まで広がっているが, 分解能 250m(領域1および2)ではかなり少なくなり, 分解能 1100m(領域2)では, NDVI が正の値の範囲内に収まっていることが分かる。

4.6 NDVIを用いた月蒸発散量の推定

NDVI から月蒸発散量を算定するため, Shin and Sawamoto⁶⁾は NOAA/AVHRR 画像を基に, 朝鮮半島の漢江流域において NDVI と月蒸発散量 E_T の関係式を導き出し, NDVI か

ら実際の蒸発散量を10%以内の誤差で推定できるとしている。Shin and Sawamoto⁶⁾における落葉樹・常緑樹の式の平均を森林の式、7月～3月の水田の式を耕作地の関係式とすると、次式が得られる。

$$\text{森林: } E_T = 211.95 \cdot \text{NDVI} - 7.75 \quad (4.22)$$

$$\text{耕作地: } E_T = 265.96 \cdot \text{NDVI} - 17.89 \quad (4.23)$$

$$\text{都市域: } E_T = 150.59 \cdot \text{NDVI} + 5.19 \quad (4.24)$$

本研究では、以上のNDVIと月蒸発散量の関係式を用いることにする。

これらの関係式は韓国で得られたものであるため、これらの式を日本の中部地方において適用することの妥当性が懸念される。しかし、さまざまな気候区分でみると、例えば Thornthwaite の気候区分²⁰⁾ や Troll による気候区分²⁰⁾ では、両地域は異なる気候区に分類されているが、Köppen の気候区分²⁰⁾ や大気大循環に基づく気候区分²¹⁾ では同じ気候区に分類されている。両地域の気候区の違いはそれほど明確でない。

上式は NOAA/AVHRR から得られたものであるが、本研究では航空機 MSS, SPOT/HRV を用いるためセンサーが異なる。しかし、波長帯はなるべく近いものを用い、DN から反射率に換算したのち NDVI を求めることにし、センサーの違いによる影響はなるべく出ないようにした。本研究で航空機 MSS 画像、SPOT/HRV 画像から得られた NDVI の領域平均値は、申²²⁾が NOAA/AVHRR から韓国で求めた10月の NDVI の値を上回っていた。これは NOAA/AVHRR の撮影時刻が早朝(7:00 頃)であり、航空機 MSS の撮影時刻は11:30 頃、SPOT/HRV の撮影時刻は10:30 頃と多少異なることに起因すると考えられる。(4.22) 式～(4.24) 式は、NOAA/AVHRR を基に得られた関係式である。これらの式に代入する NDVI の値は、なるべく NOAA/AVHRR に近い条件のものにしたい。このため次のような処理をした。NOAA/AVHRR からの NDVI(n) と、航空機 MSS 画像、SPOT/HRV 画像からの NDVI の平均値(m) の比(r)を計算し($n = r \cdot m$)、航空機 MSS 画像、SPOT/HRV 画像の各ピクセルで計算された NDVI の値に r を乗じてから、関係式に代入し月蒸発散量を求める。このような工夫をして、(4.22) 式～(4.24) 式を適用することとした。

本研究では、月蒸発散量の推定精度を詳細に議論することが目的ではなく、NDVI を用いた蒸発散量推定に空間分解能が及ぼす影響に主眼をおいているため、分解能が推定月蒸発散量へ与える影響を数値実験的に観察できればよい。

4.7 空間分解能が月蒸発散量推定値に及ぼす影響

領域1と領域2において、(4.22) 式、(4.23) 式、(4.24) 式を用いて森林、耕作地、都市域の月蒸発散量を推定した結果が Figure 4.7(b), (c), (d), Figure 4.8(b), (c), (d) である。これらの結果を総合して、領域全体の蒸発散量 (Figure 4.7(a) と Figure 4.8(a)) を算定した。NDVI のときと同様に、水域は領域全体の1%に満たないため領域外とした。

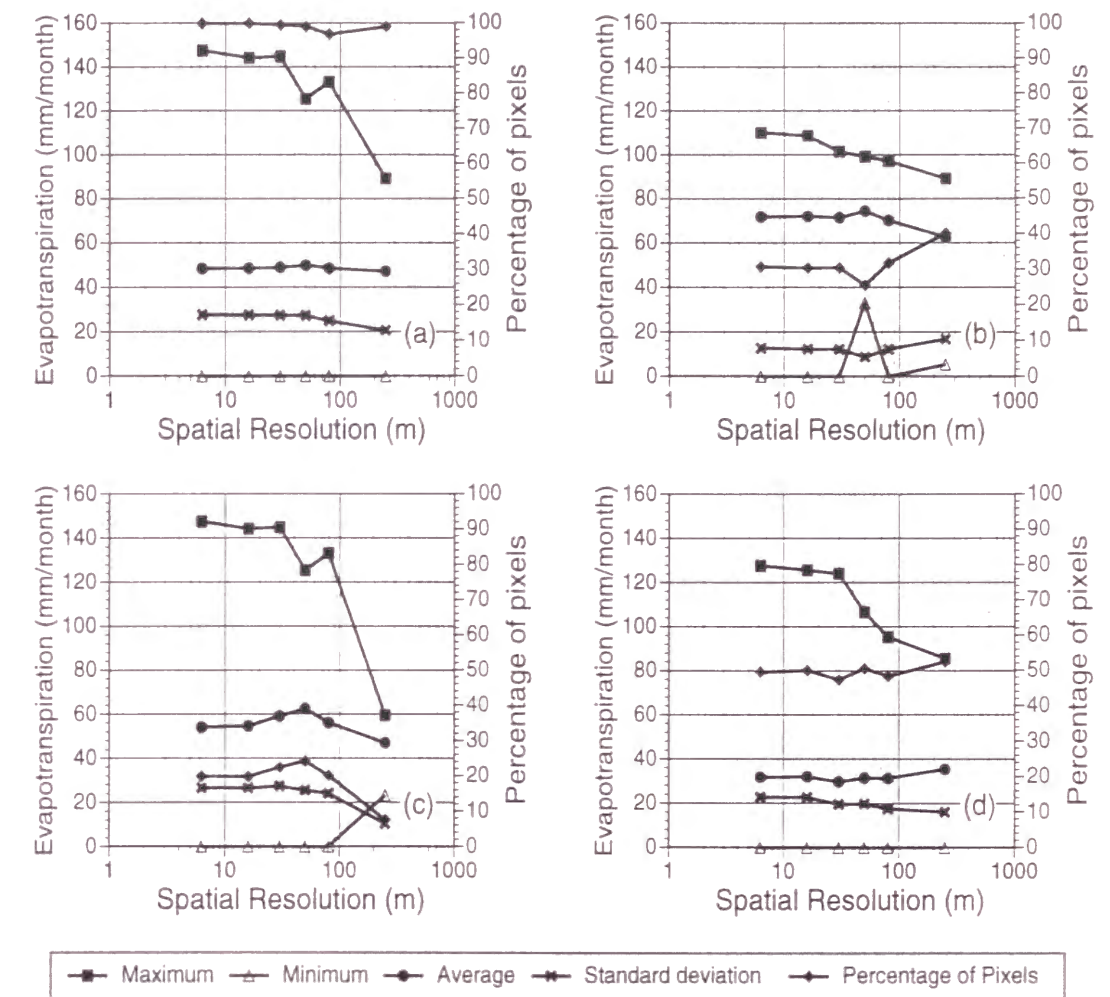


Figure 4.7 Relationship between spatial resolution and estimated evapotranspiration in Site 1.

4.7.1 領域全体の統計量

領域1における推定月蒸発散量の領域平均は、分解能 6.25 m で 48 mm/month、分解能 250 m で 47 mm/month であり、分解能によってほとんど変化しなかった。標準偏差は、分解能 50m まではほとんど変化しない(約 27mm/month)が、80m(24.8mm/month)、250m(20.6mm/month) となるにつれて平滑化の効果が出てきて徐々に小さくなった。最大値は徐々に小さくなり、最小値は常に 0mm/month であった。

Plate 4.10に領域1における 6.25 m、50 m、250 m の推定月蒸発散量の分布を示す。非常に蒸発散量が高いピクセルが、分解能 6.25 m の画像では見えるが、分解能が粗くなるにつれ、ほとんど無くなっていることが分かる。

次に、領域2における推定月蒸発散量の領域平均は、約 61mm/month であり、分解能に

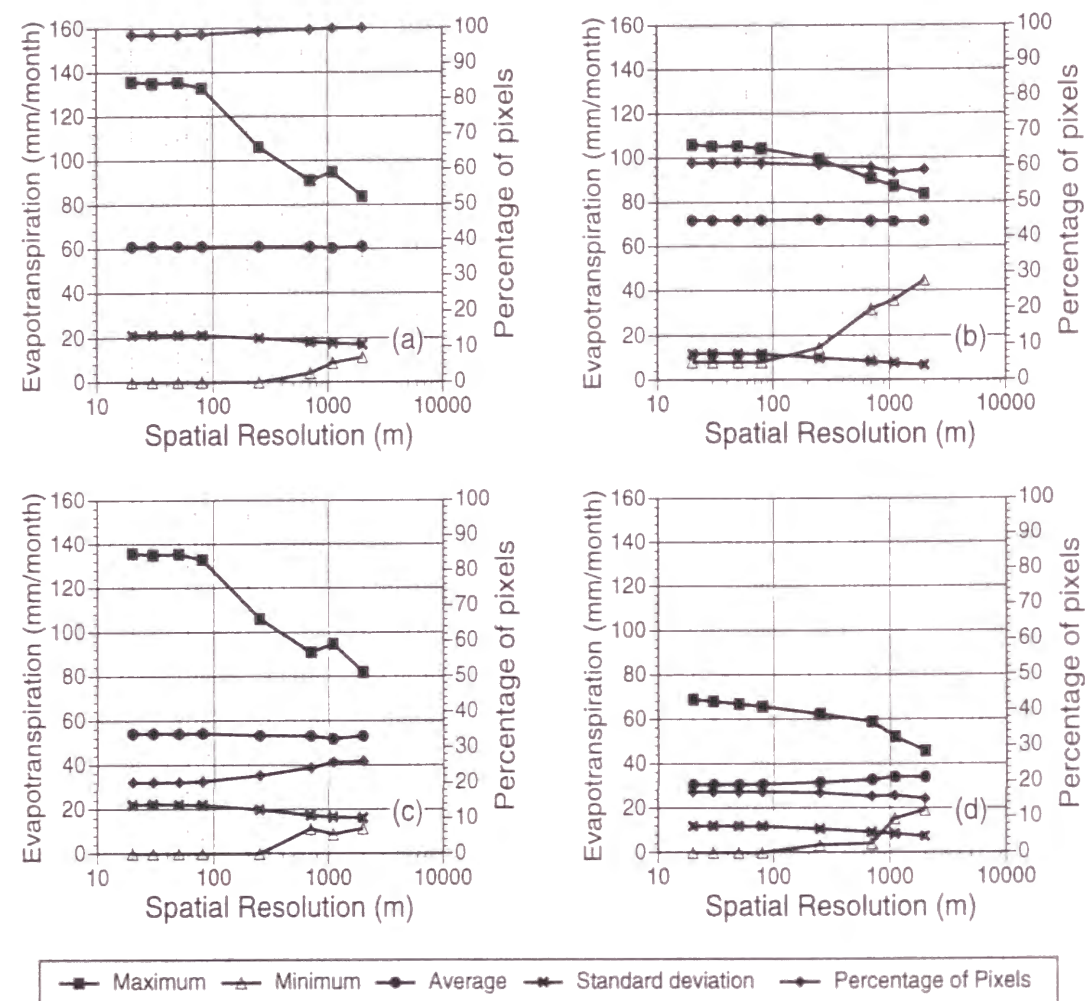


Figure 4.8 Relationship between spatial resolution and estimated evapotranspiration in Site 2.

よってほとんど変化しなかった。標準偏差は、分解能 80m まではほとんど変化しない(約 21mm/month)が、250m では 20.0mm/month, 700m では 18.3mm/month, 2000m では 17.1mm/month と、分解能が粗くなるにつれて平滑化の効果が出てきて徐々に小さくなった。最大値は徐々に小さくなり、最小値は分解能 250m までは常に 0mm/month であった。

Plate 4.10に領域 2 における 20 m, 250 m, 1100 m の推定月蒸発散量の分布を示す。領域 1 と同様に、非常に蒸発散量が高いピクセルが、分解能が粗くなるにつれ、平滑化によって減少していくことが見て取れる。

4.7.2 土地被覆クラス毎の統計量

Figure 4.7(b), (c), (d) からは、領域 1 における、森林、耕作地、都市域の各分類クラスごとの領域平均値は、領域全体に比べて分解能による変化が多少大きくなっていることが分かる。その他、標準偏差、最小値、最大値の分解能による変化は、NDVI における変化に追従している。

領域 2 においても、各分類クラスごとの領域平均値は、領域全体に比べて分解能による変化が多少大きくなっており、標準偏差、最小値、最大値の分解能による変化は、NDVI における変化に追従している (Figure 4.8(b), (c), (d))。

近藤純正ら²³⁾は気象観測所の月平均気象データを用いてバルク式により日本の各地の森林の月蒸発散量を推定している。そこでは、対象領域に近い名古屋の 10 月の月蒸発散量を 71mm/month と推定している。本研究では、森林の平均値は領域 1 では約 70mm/month, 領域 2 では約 72mm/month と推定されている。このことから、NDVI と月蒸発散量の関係式による蒸発散量推定と、物理式であるバルク式を用いた蒸発散量推定は、ほぼ同等の推定値となることが分かる。


4.7.3 ヒストグラムによる考察

Figure 4.9に、領域 1 の分解能 6.25m, 50m, 250m の推定月蒸発散量のヒストグラムを、Figure 4.10に、領域 2 の分解能 20m, 250m, 1100m の推定月蒸発散量のヒストグラムを示す。NDVI と同様に分解能が粗くなるとヒストグラムの定義域が狭まり、相対頻度が高くなることが分かる。また、都市域、森林、耕作地のヒストグラムの定義域はそれぞれ異なることが確認できる。


Shin and Sawamoto⁶⁾が導き出した (4.22) 式~(4.24) 式は線形であるため、NDVI が小さいとき月蒸発散量が 0mm/month になることがありうる。また逆に非常に月蒸発散量が高いピクセルも存在する。このことから、月蒸発散量は NDVI の上限および下限において、それぞれある一定値に漸近していく NDVI に関する単調増加関数でモデル化できると考えられる。

また、分解能 6.25m(領域 1) では、0mm/month となるピクセルの相対頻度が非常に高いが、分解能 250m(領域 1 および 2) ではそれが目立たなくなり、分解能 1100m(領域 2) ではそのようなピクセルがなくなっていることが Figure 4.9, Figure 4.10 から分かる。これは分解能が粗くなることによる平滑化の効果である。


(4.22) 式~(4.24) 式は、分解能 1100m の NOAA/AVHRR 画像から得られた式である。分解能 1100m 程度まで空間的な平滑化がされると、極端に NDVI が高いピクセル、低いピクセルはなくなり、(4.22) 式~(4.24) 式のような線形式を用いても、月蒸発散量が 0mm/month になるようなピクセルが現れなくなるものと考えられる。すなわち、分解能がある程度以上 (Figure 4.8によれば 700m) 粗ければ、平滑化によって NDVI と月蒸発散量の関係が線形とみなせる範囲に NDVI の値が収まるといえる。



(a) 6.25 m




(b) 50 m




(c) 250 m


Figure 4.9 Histograms of estimated evapotranspiration in Site 1.



(a) 20 m



(b) 250 m



(c) 1100 m

Figure 4.10 Histograms of estimated evapotranspiration in Site 2.

4.8 土地利用の割合による月蒸発散量の推定

4.8.1 F-C-U ダイアグラム

ある領域 A の月蒸発散量の領域平均値 E_T は、以下の式で表現される。

$$E_T = A_F \int_0^{\infty} x \cdot f_F(x) dx + A_C \int_0^{\infty} x \cdot f_C(x) dx + A_U \int_0^{\infty} x \cdot f_U(x) dx \quad (4.25)$$

ここで、 x は月蒸発散量、 $f_F(x)$ 、 $f_C(x)$ 、 $f_U(x)$ は、それぞれ 0 から ∞ について積分すると 1 となる確率密度関数、 A_F 、 A_C 、 A_U は、それぞれ領域 A における森林、耕地、都市域の占める割合である。ただし、

$$A_F + A_C + A_U = 1 \quad (4.26)$$

である。

したがって、確率密度関数 $f_F(x)$ 、 $f_C(x)$ 、 $f_U(x)$ が定まれば、任意の A_F 、 A_C 、 A_U の組合せに対して月蒸発散量の推定ができる。

すべての土地被覆が森林、耕地、都市域のどれかに当てはまるならば、 A_F 、 A_C が決まれば A_U も決まる ((4.26) 式)。これにより、例えば縦軸に A_F 、横軸に A_C を取った平面を考えると、土地被覆状態は平面上の 1 点で表される。これを図にすると Figure 4.11 のようになる。これを、F-C-U ダイアグラムと呼ぶことにする。

航空機 MSS 画像が取得された 1992 年では、森林が対象領域全体の 30.7%、水田が 19.8%、都市域が 49.5% を占めている ($A_F=0.307$ 、 $A_C=0.198$ 、 $A_U=0.495$)。分解能 6.25 m のヒストグラムから経験的に導き出した $f_F(x)$ 、 $f_C(x)$ 、 $f_U(x)$ を用いると、推定月蒸発散量は約 48mm/month であった。これは、Figure 4.11 の「1992」と示されている点である。森林の半分が市街化され、森林が領域全体の 15%、都市域が 65.2% に土地被覆が変化したとき ($A_F=0.15$ 、 $A_C=0.198$ 、 $A_U=0.652$) の月蒸発散量は、42mm/month と推定された。これは、Figure 4.11 の「More Urbanized」と示されている点である。F-C-U ダイアグラムでは都市化が進展している領域ほど原点の近くにプロットされるため、都市化の進展具合をプロットの位置によって知ることができる。

この F-C-U ダイアグラムを用いることにより、気象データを用いることなく、リモートセンシングデータによる土地被覆分類や、土地利用図などのみを用いて、月蒸発散量を容易に推定することが可能である。

4.8.2 日本全国 2km メッシュ土地利用データを用いた月蒸発散量の推定

前述の通り、領域内の土地被覆状態が分かれば、F-C-U ダイアグラムを用いて蒸発散量を推定することが可能である。ここでは、土地被覆情報として、氷見山幸夫教授が作成した 2km メッシュ日本全国土地利用データセット²⁴⁾を用いて月蒸発散量の推定を試みる。




Figure 4.11 F-C-U diagram for evapotranspiration in October.

2km メッシュ日本全国土地利用データセットでは、日本全国の土地利用を 31 クラスで表現している。この 31 クラスを基に森林、耕地、都市域の 3 クラスに再分類した。明治・大正期 (1900 年)、昭和中期 (1950 年)、現代 (1985 年) の名古屋市周辺 (約 2630km²; 領域 3) の土地被覆状態を Plate 4.12 に示す。白線で囲まれた部分が領域 3 である。現代に近づくにつれ都市域 (赤) の領域が広がっている。

領域 3 は領域 1 を含むため、先ほどと同じく 1992 年の航空機 MSS 画像から得られた F-C-U ダイアグラムを用いることができる。森林、耕地、草地の割合と推定蒸発散量は Table 4.2 のようにまとめられる。その結果、明治・大正期 (1900 年)、昭和中期 (1950 年)、現代 (1985 年) の名古屋市周辺の月蒸発散量の領域平均値はそれぞれ、64.4mm/month、62.4mm/month、57.2mm/month と推定された。それぞれ、Figure 4.11 において、「1900」、「1950」、「1985」と示されている点である。Figure 4.11 からは、名古屋市周辺では、月蒸発散量が都市化に伴い徐々に減少していると推測される。

Table 4.2 Spatial resolution of various raster data

	A_F	A_C	A_U	Evapotranspiration (mm/month)
1990	60.80	37.44	1.76	64.39
1950	58.56	32.64	8.80	62.41
1985	52.73	19.94	27.33	57.22

4.9 結語

本章では、都市域・森林・耕作地が混在する地域に対して、空間分解能の異なる疑似画像を生成し、NDVIの分解能による変化と、NDVIと月蒸発散量の関係式を用いた月蒸発散量の推定に分解能が及ぼす影響について検討を行った。得られた成果をまとめると以下のようである。

1. NDVIの領域平均値は、領域1、領域2ともに分解能によってあまり変化しなかった (Figure 4.3, Figure 4.4)。推定月蒸発散量の領域平均値も、NDVIの場合と同様に、領域1、領域2ともに分解能によってあまり変化しなかった。このことから、数100km²の領域 (領域2の広さ程度) の月蒸発散量を、リモートセンシング画像から得られるNDVIを基に推定する場合には、数mから2km程度までのどの分解能で考えてもそれほど問題はないと思われる。
2. この時期 (10月) の森林域の月蒸発散量の平均値は、本研究の手法によって領域1 (瀬戸・長久手; 3.2×6.4 km) では約70mm/month、領域2 (瀬戸市周辺; 20.5×41.0 km) では約72mm/monthとそれぞれ推定された。これは、近藤純正ら²³⁾がバルク式によって推定した名古屋の10月の月蒸発散量 (71mm/month) とほぼ同じ値である。
3. 線形のNDVIと月蒸発散量の関係式を用いた場合、高分解能リモートセンシング画像からは極端に推定値が高すぎたり、0mm/monthとなる領域が発生する。高分解能リモートセンシング画像を用いた月蒸発散量の推定には、線形ではなく、ある上限値、下限値に漸近していくNDVIと月蒸発散量の関係式が必要である。しかし、低分解能の (700m程度より粗い) リモートセンシング画像を用いた場合は、平滑化の影響によって、関係式を線形で仮定しても良いと考えられる。
4. F-C-Uダイアグラムを用いて、1992年時点よりもさらに都市化が進展したときの月蒸発散量を推定した。領域1の森林の半分が市街化され、森林が領域全体の15%、都市域が65%に変化したとすると、領域平均の月蒸発散量は現在の約48mm/monthから約42mm/monthに減少すると予測された。また、名古屋市周辺 (約2630km²; 領域3) の蒸発散量は、明治・大正期から徐々に減少していると推測された。


以上の結果は、1992年10月の矢田川航空機実験のときに得られた航空機MSS画像、SPOT/HRV画像に基づくものである。場所的・時期的に普遍性のあるものにするために

は、さらなる検証が必要である。しかしながら、河川流域において空間的に分布する物理量やパラメータとリモートセンシング画像の空間分解能との関係を把握しておくことは、水文流出系の地域規模・地球規模での解析において基本的に重要である。


参考文献

- 1) 古藤田一雄・甲斐憲次・中川慎治・吉野正敏・星 仰・武田 要・関 利孝: ランドサットデータによる土地利用区分と広域蒸発散量算定手法の開発に関する研究, 筑波大学水理実験センター報告, No. 8, pp.57-66, 1984.
- 2) Kotoda, K.: Estimation of river basin evapotranspiration from consideration of topographics and land use conditions, Estimation of Arial Evapotranspiration (*Proceedings of a workshop held at Vancouver, B. C., Canada, August 1987*), IAHS Pub. 177, pp. 271-281, 1989.
- 3) Hoshi, T., S. Uchida, K. Kotoda: Development of a system to estimate evapotranspiration over complex terrain using Landsat MSS, evaluation and meteorological data, *Hydrological Sciences Journal*, Vol. 34, No. 6, pp. 625-649, 1989.
- 4) 多田 毅・風間 聡・沢本正樹: NDVIを用いた広葉樹林帯の蒸発散分布推定, 水文・水資源学会誌, Vol. 7, No. 2, pp. 114-119, 1994.
- 5) 申 士澈・沢本正樹: 漢江流域における水文量の広域空間特性の解析, 水文・水資源学会誌, Vol. 8, No. 6, pp.560-567, 1995.
- 6) Shin, S. and M. Sawamoto: Evaluation of the annual water balance through vegetation monitoring, *International Conference on Water Resources & Environment Research: Towards the 21th Century* (Volume I), Water Resources Research Center Kyoto University, Japan, pp. 635-641, 1996.
- 7) Seevers, P. M. and R. W. Ottmann: Evapotranspiration estimation using a normalized difference vegetation index transformation of satellite data, *Hydrological Sciences Journal*, Vol. 39, No. 4, pp. 333-345, 1994.
- 8) 佐渡公明: 衛星データを用いた広域蒸発散量の推定, 水文・水資源学会誌, Vol. 7, No. 4, pp.315-324, 1994.
- 9) 佐渡公明・児島正洋: ランドサット TM データのみを用いた重回帰式による実蒸発散量の推定, 水工学論文集, Vol. 40, pp.323-328, 1996.
- 10) 近藤昭彦: Global Vegetation Index と気候学的推定法による蒸発散量計算値の対応関係, 写真測量とリモートセンシング, Vol. 34, No. 2, pp. 6-14, 1995.


- 11) 近藤昭彦: モンスーンアジアにおける人為的土地被覆変化による蒸発散量変化の推定, 写真測量とリモートセンシング, Vol. 34, No. 4, pp. 13-21, 1995b.
- 12) Ray, T. W.: A faq on vegetation in remote sensing, ftp://kepler.gps.caltech.cdu/pub/terrill/rsvegfaq.txt, 1994.
- 13) 宝 馨・立川康人・近藤昭彦・西尾邦彦・芝野博文・執印康裕・田中隆文・小池俊雄・北田勝紀・富井直弥: 矢田川航空機実験及び同期地上観測実験について, 水文・水資源学会誌, Vol. 6, No. 1, pp. 71-75, 1993.
- 14) 会田 勝: 大気と放射過程 —大気の熱源と放射収支を探る—, 気象学のプロムナード 8, 東京堂出版, 1990.
- 15) 近藤純正 編集: 水環境の気象学 —地表面の水収支・熱収支—, 朝倉書店, 1994.
- 16) 国立天文台 編集: 理科年表, 丸善, 1997.
- 17) 石黒鉄治・宝 馨・芝野博文・立川康人・岡 太郎・児島利治: 航空機 MSS 画像による植生判別 — R-IR プロット及び様々な植生指標を用いて —, 平成7年度文部省科学研究費補助金(総合研究(A))研究成果報告書, 05302077, 代表: 西尾邦彦, 東京農業大学, pp. 11-22, 1996.
- 18) 高木幹雄・下田陽久 監修: 画像解析ハンドブック, 東京大学出版会, pp. 445-447, 1991.
- 19) 財団法人 リモート・センシング技術センター: SPOT データ CCT フォーマット説明書, p. 62, 1986.
- 20) 福井栄一郎 編集: 気候学, 現代地理学体系 I, 自然地理・応用地理 第2巻, 古今書院, pp. 200-220, 1962.
- 21) 中村和郎・木村竜治・内嶋善兵衛: 日本の気候, 日本の自然 5, 岩波書店, pp. 213-221, 1986.
- 22) 申 士澈: 植生観測による水文量の分布特性の評価および水収支に関する研究, 東北大学大学院博士学位論文, 1996.
- 23) 近藤純正・中園 信・渡辺 力・桑形恒男: 日本の水文気象 (3) - 森林における蒸発散量 -, 水文・水資源学会誌, Vol. 5, No. 4, pp. 8-18, 1992.
- 24) GRID-つくば: 全国土地利用図表示システム, 国立環境研究所 地球環境研究センターニュース, Vol. 7, No. 3, p. 13, 1996.



(a) Original AMSS image with a resolution of 6.25 m



(b) Simulated image with a resolution of 50 m



(c) Simulated image with a resolution of 250 m



Plate 4.6 Original and simulated false color images in Site 1.

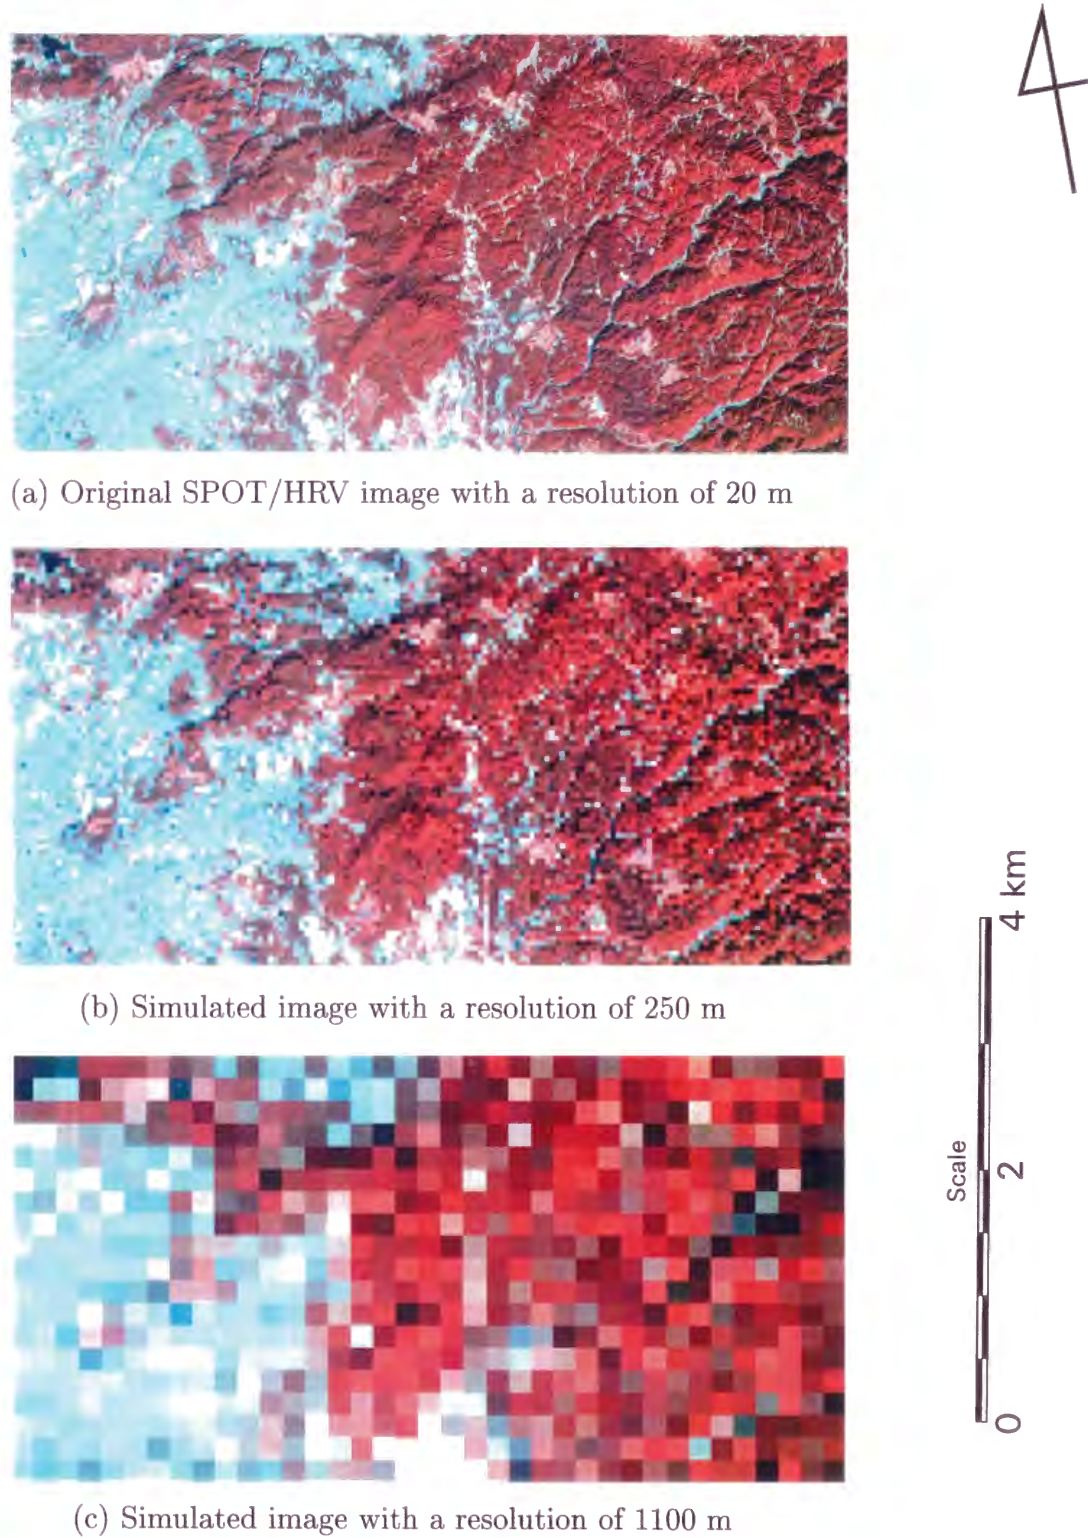




Plate 4.7 Original and simulated false color images in Site 2.



(a) Original AMSS image with a resolution of 6.25 m



(b) Simulated image with a resolution of 50 m



(c) Simulated image with a resolution of 250 m







Plate 4.8 Distribution of NDVI in Site 1.



(a) Original SPOT/HRV image with a resolution of 20 m



(b) Simulated image with a resolution of 250 m



(c) Simulated image with a resolution of 1100 m








Plate 4.9 Distribution of NDVI in Site 2.



(a) Original AMSS image with a resolution of 6.25 m




(b) Simulated image with a resolution of 50 m




(c) Simulated image with a resolution of 250 m


Plate 4.10 Distribution of evapotranspiration in Site 1.



(a) Original SPOT/HRV image with a resolution of 20 m



(b) Simulated image with a resolution of 250 m



(c) Simulated image with a resolution of 1100 m




Plate 4.11 Distribution of evapotranspiration in Site 2.

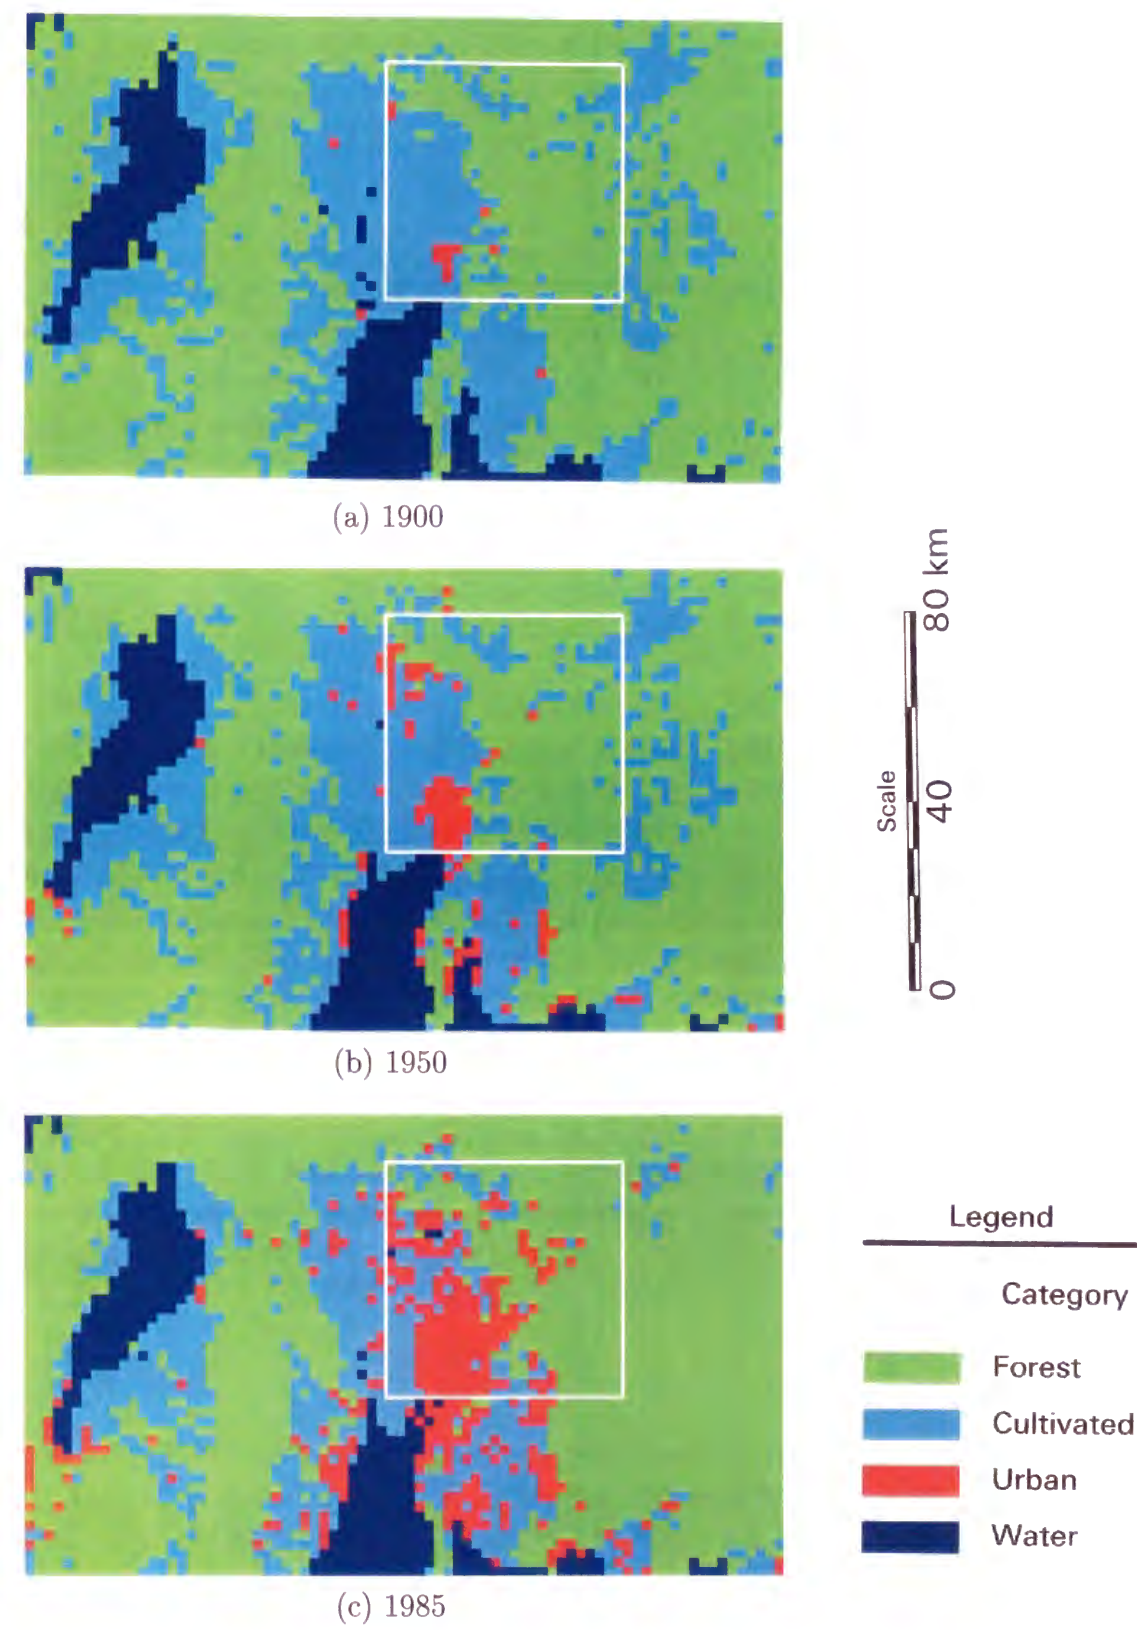


Plate 4.12 Land use in Site 3.

第5章

ラスター型空間情報の分解能が分布型流出解析結果に及ぼす影響

5.1 概説

3章, 4章において, リモートセンシング画像の分解能と分類精度との関係, リモートセンシング画像の分解能と植生指標 (NDVI) 及びそれに基づく蒸発散量の推定値の関係, といったリモートセンシング画像の分解能が水文解析に及ぼす影響に関する研究を行ってきた。本章では, 流域の水収支を考える上で重要な問題の一つ, 流出解析に焦点を当てる。

流出解析に応用するラスター型空間情報としては, まず DEM の利用が思いつかれるだろう。流出解析と DEM の分解能との関係については, DEM から算定された集水面積, 河道長, 落水線の勾配等の流出モデルを作成する上での流域情報と DEM の分解能との関係を調べた研究がなされている¹⁾²⁾。また, DEM のグリッド交点一つ一つからの流出を全て追跡する新しいタイプの分布型流出モデルの提案もされている³⁾。

しかし, 実際に DEM の分解能が流出解析の結果得られる計算ハイドログラフの形状に, どの程度影響を及ぼすかについての検討はあまりなされていない。そこで, 本研究では, DEM やリモートセンシング画像等のラスター型空間情報を用いた分布型流出モデルを提案し, ラスター型空間情報の空間分解能が, どの程度流出解析結果に影響を及ぼすかを実際の流域に適用して調べる。

5.2 対象流域

対象流域は, 一級河川庄内川の 17.5 km 地点で合流する矢田川とする。この流域は, 流域面積 110 km², 主河道長 42 km である。Figure 5.1に, 対象流域周辺の図を示す。この流域は, 近年, 急激に市街化の進んでいる地域であり, 特に下流域でその傾向は著しい。

水文資料については, 矢田川左支川香流川流域で, 水位・流量が建設省庄内川工事事務所により観測されている。また, 庄内川との合流点から約 4 km 上流の瀬古地点で, 庄内川工事事務所により水位観測がなされている。これに加えて, 愛知県でも雨量・水位の観測

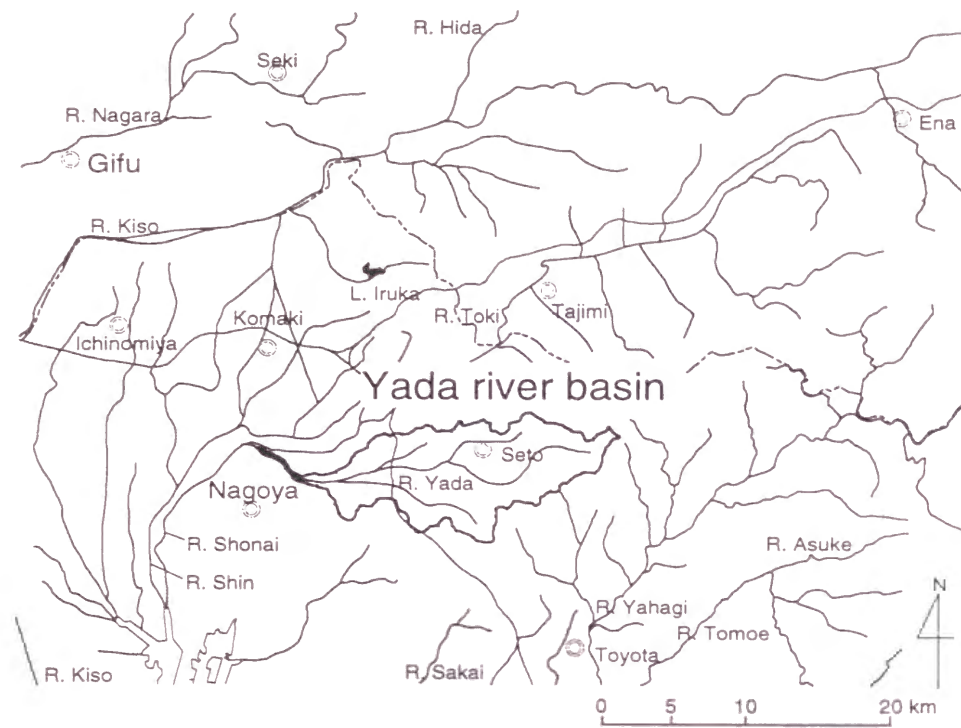


Figure 5.1 Test site.

を実施しており、流域規模の割には比較的多くの水文資料が存在している流域である。また、御在所レーダー雨量計の観測範囲内に位置しており、雨量の空間分布の情報を得ることも可能である。

5.3 セル分布型流出モデル

5.3.1 セル分布型流出モデルの概要

本研究では、次のような分布型の流出モデルを用いる。

- DEMの標高値(グリッド交点)の周囲50×50 mまたは250×250 m等、DEMの分解能に合わせた正方形の領域を1つの部分流域(セル)と考え、流域全体が正方形の部分流域(セル)が多数集まってできているとする。
- DEMから流域の落水線図(5.3.3節参照)を作成し、一つのセルからの流出は、落水線の流下方向のもう一つのセルへのみ起こるとする。
- 各セルでは、セル内で一様な有効降雨を入力とし、上流側セルからの流出を合計して上流端流入量とし、kinematic wave法によって流出量を計算する。

5.3 セル分布型流出モデル

- 8つの流下方向のうち、上下左右方向へ流出するセルでは、斜面長、斜面幅はともに分解能と同じ d mとし、斜め方向へ流出するセルでは、斜面長は $\sqrt{2}d$ mとし、斜面幅は $d/\sqrt{2}$ mとする。

kinematic wave法の基礎式は次式で表される。

$$\frac{\partial h}{\partial t} + \frac{\partial q}{\partial x} = r_e \quad (5.1)$$

$$q = \frac{\sqrt{I}}{N} h^m \quad (5.2)$$

ここで、 q : 単位幅流量、 h : 水深、 r_e : 有効雨量、 I : 斜面勾配、 N : 等価粗度、 m : 定数(=5/3)である。

この(5.1)、(5.2)式をLax-Wendroff型の差分スキーム⁵⁾で解き、セル内に設けたノードそれぞれにおいて降雨を入力する横流入を取り扱うことにより、kinematic wave理論に基づく流出現象を忠実に計算する。

このような、正方形の部分流域(セル)によって流域を構成する流出モデルをセル分布型流出モデルと呼ぶこととする。

5.3.2 実河道の近似

落水線図はDEMから作成される。しかし、DEMの分解能と地形の起伏条件によっては、実際とは異なった河道網が形成される事も少なくない。そのため、落水線図を作成する際の事前情報として、実河道の位置データを入力することが必要である。

実河道の位置データは、地形図からデジタイザを用いて取得する。Figure 5.2に1/50,000の地形図から取得した矢田川流域の実河道の位置データ(実河道データ)を示す。

しかし、得られた実河道データは、例えばFigure 5.3(a)のように、DEMのグリッド交点と必ずしも一致しない。そこで、実河道の位置データを、Figure 5.3(b)のようにそれに最も近いグリッド交点で置き換える。Figure 5.3(b)で灰色で示された線が実河道データ、太線がグリッド交点で置き換えられた近似河道データである。

このようにして生成された近似河道データは、5.3.3節において落水線図を作成するときや、5.3.4節において流域の土地利用を決定する際に使用する。Figure 5.4とFigure 5.5、Figure 5.6にそれぞれ分解能50 m、150 m、250 mでの近似河道を示す。分解能50 mの近似河道は、実河道データ(Figure 5.2)に非常によく似ている。近似河道の分解能が150 m、250 mになるにつれて、実河道データが近似されていく(粗くなっていく)様子が分かる。

5.3.3 落水線図の作成

落水線図は、DEMと近似河道データを用いて、以下のルールに基づいて作成する。

- DEMの標高値の周囲8方向のうちの最急勾配方向を求め、その方向に落水線を描く。



Figure 5.2 Actual channel network from the 1/50,000 topographic map




Figure 5.3 Making of approximate channel network.



Figure 5.4 Approximate channel network with 50-m resolution.




Figure 5.5 Approximate channel network with 150-m resolution.




Figure 5.6 Approximate channel network with 250-m resolution.

- 最急勾配方向が複数ある場合、周囲8方向の先の領域(例えば、左上ならばFigure 5.7における影の領域)内のグリッド交点の平均標高値が最も低い方向へ落水線を描く。
- 標高値が周囲の8点の全てより低いとき、すなわち窪地となっているグリッド交点では、周囲24点の中で最も低いグリッド交点の方向へ落水線を描く。Figure 5.8(a)で、グリッド交点番号(1)の標高値が最も低ければ、中心(グリッド交点番号(13))からの落水線は、Figure 5.8(a)のように、矢印から破線矢印の方向に落水線が描かれることを期待して、グリッド交点番号(7)の方向へ落水線を描き、グリッド交点番号(7)において、新たに周囲8方向のうちの最急勾配方向を求める。また、グリッド交点番号(2)の標高値が最も低ければ、中心からの落水線は、Figure 5.8(b)のように、グリッド交点番号(7)、(8)のうち、中心からの勾配の急な方向へ描かれ、グリッド交点番号(7)または(8)において、新たに周囲8方向のうちの最急勾配方向を求める。
- 近似河道データにおいて河道とされたセルでは、必ず河道の流下方向へ落水線が描かれる。

本研究では、DEMデータに、国土地理院が発行している数値地図50mメッシュ(標高)を用いる。数値地図50mメッシュ(標高)は、1/25,000の地形図に緯線・経線に沿って200本づつ引いたグリッドの交点の標高を読みとって作成されたものなので、正確に50×50mの分解能ではない。そのため、まず数値地図50mメッシュ(標高)を内挿して、平面直角座標系上で正確に分解能50×50mのDEMデータを作成し、分解能50mのDEMを基に分解能250mのDEMを生成した。Figure 5.9, Figure 5.10, Figure 5.11に、それぞれ分解能50m, 150m, 250mのDEMから生成した落水線図を示す。生成されたそれぞれの落水線図の最上流端が、すなわち流域界である。分解能50m, 150m, 250mの落水線図の




Figure 5.7 Illustration of decision about drainage direction.




Figure 5.8 Illustration of decision about drainage direction.



Figure 5.9 Drainage paths with 50-m resolution.

各流域界はどれも似通っている。このことから、分解能 50 m から 250 m の間では、落水線図から得られる流域界はほぼ同じものが得られると言える。

5.3.4 モデル定数の決定

等価粗度

各セルの等価粗度 N は土地利用によって決定されるものとする。土地利用情報は、リモートセンシング画像から得られる。リモートセンシング画像は、前節の数値地図 50m メッシュ (標高) と同様に、50 m の分解能を持ってはいない。そのため、DEM の場合と同様に、元のリモートセンシング画像からそれぞれの分解能の疑似リモートセンシング画像を生成する必要がある。

本章では、1992 年 10 月に取得された、分解能 30 m の Landsat-5/TM 画像を基に、2 章で示した、MTF を応用した低分解能化アルゴリズムによって、分解能 50 m、分解能 150 m、分解能 250 m の疑似リモートセンシング画像を生成した。その際、疑似リモートセンシング画像の画素の平面直角座標系における位置座標は、それぞれ対応する分解能の DEM のグリッド交点の位置座標と一致するように生成する。すなわち、セル分布型流出モデルのセルと疑似リモートセンシング画像の画素とは 1 対 1 に対応している。

生成された疑似リモートセンシング画像を、最尤分類法を用いて森林 (Forest)、水田 (Paddy)、草地 (Grass)、都市域 (Urban)、水域 (Water) の 5 クラスに土地利用分類した。Plate 5.13, Plate 5.14, Plate 5.15 にそれぞれ分解能 50 m、150 m、250 m の分類結果を示す。

しかし、分解能 150 m、250 m の分類結果においては、細密数値情報 (Plate 5.16) と比較して、明らかに水域の領域が広すぎる。




Figure 5.10 Drainage paths with 150-m resolution.




Figure 5.11 Drainage paths with 250-m resolution.

3章の解析結果 (Figure 3.3) では, 分解能 28 m, 30 m と分解能が粗くなると, 水域の UA のみが 15% 以下と非常に分類精度が悪くなる. 水域の UA が悪いということは, 実際には水域ではないが水域に分類された領域が多いということである. 3章での解析結果と, Plate 5.13, Plate 5.14, Plate 5.15 の分類結果から, 分解能が粗くなるにつれて水域に誤分類される領域が多くなっているという結論が導き出される. 細密数値情報や分解能 50 m での分類結果では, 水域は全領域の 1% に満たなかった. そこで分解能 150 m, 250 m に関しては, 水域という分類クラスを除いて, 森林, 水田, 草地, 都市域の 4 クラスに土地利用分類した (Plate 5.17, Plate 5.18).

また, 近似河道データにおいて河道とされているセルは, 河川 (River) というクラスに分類する. 土地利用ごとの等価粗度は, 一般的に kinematic wave 法で用いられる値⁴⁾を参考値とし, 値を変えて再計算を行い, 計算ハイドログラフがどのように変化するかを観察する.

斜面勾配

斜面勾配 I_i は DEM から求める. セル i における標高値 z_i (m) と, 落水線図から分かるそのセルからの流出が流入するセル j における標高値 z_j (m), セル i, j の中心間の距離 d (m) から, セル i における斜面勾配 I_i

$$I_i = \frac{z_i - z_j}{\sqrt{(z_i - z_j)^2 + d^2}} \quad (5.3)$$

を求める. ただし, 落水線図を生成する際の窪地の処理のため, 上り勾配となっている落水線が存在する. そのような場合には, 標高差 10cm の下り勾配とみなして計算した. 数値地図 50 m メッシュ (標高) での標高値の最小単位が 10cm のためである.

5.3.5 流出モデルの検証

本研究で提唱したセル分布型流出モデルの検証のため, 次のような仮想斜面において流出解析を行った.

- 斜面長: $L = 250$ m
- 斜面幅: $B = 250$ m
- 等価粗度: $N = 0.7$
- 勾配: $1/50$, すなわち $I = \frac{1}{\sqrt{2501}}$

すなわち, 分解能 250 m では, Figure 5.12(c) のように, 250×250 m の 1 つのセルのみからなる流域を仮定し, 分解能 125 m では, 125×125 m のセルが 4 つ, Figure 5.12(b) のように連結された流域を仮定し, 分解能 50 m では, 50×50 m のセルが 25 個, Figure 5.12(a) のように連結された流域を仮定する. 分解能 125 m と 50 m では, 最下段のセルからの流出をすべて合計した値を仮想流域からの流出とみなす.




Figure 5.12 Drainage paths for the simulation slope.

分解能 50 m, 125 m, 250 m について, すべてのセルにおいて 10 mm/hr の矩形降雨を 4 時間降らせ, 流出計算を行った. 1つのセル内の差分のノード数を 10 にした場合の計算結果を Figure 5.13に示す. theoretical とある実線は, kinematic wave 理論に基づき, 特性曲線を解いて得られる理論的な解である. 3つの分解能によるそれぞれの計算ハイドログラフは, ハイドログラフの立ち上がり, ピーク流量, ハイドログラフの逓減部などは理論解に極めて近く, 妥当な計算結果が得られたと言える.


同様に, ノード数を 2, 4, 6, 8 にした場合のハイドログラフをそれぞれ Figure 5.14, 5.15, 5.16, 5.17に示す. ノード数 2 では, どの分解能でも, ピーク流量はほぼ良い値が計算されるが, ハイドログラフの立ち上がり, 逓減部ともに理論解とはかなり異なり, 妥当な計算結果とは言えない. ノード数 4 では, ノード数 2 と比べてかなり改善されている. しかし, 分解能 50 m では, ハイドログラフの立ち上がり, 逓減部が理論解とはまだ異なる. 分解能 125 m, 250 m では, ハイドログラフの逓減部はかなり改善されているが, 立ち上がりがまだ理論解とは異なる. とくに, ハイドログラフがピークに到達するとき, 理論解のピーク流量を超過した流量を示すことが目立つ. ノード数 6 では, 分解能 50 m のハイドログラフのピークの立ち上がりが理論解と多少異なっている. 分解能 125 m では, ピークの到達時刻が多少遅れている. 分解能 250 m では, ピーク到達時刻が多少遅れ, なおかつノード数 4 と同様にハイドログラフがピークに到達するとき, 理論解のピーク流量を超過した流量を示すことが目立つ. ノード数 8 では, ノード数 6 に比べて, それぞれ改善されているが, まだ理論解との差異が多少見える.

以上の結果より, 本研究の流出モデルにおいて, 各セルにおけるノード数が 10 以上になれば, かなり妥当な計算結果が得られるといえる.


さらにノード数 15 の場合のハイドログラフを Figure 5.18に示す. ノード数 10 の結果 (Figure 5.13) に比べてそれほど大きく改善されてはいない. むろん, ノード数が多くなればなるほど流出計算の精度は向上するが, それだけ計算時間も増大する. 以上より, 本研究では, ノード数を 10 として計算することにする.

分解能 50 m でも 250 m でも, 妥当な結果が得られるノード数が同じである理由は次のように考えられる. 本研究で各セルにおいて流出を計算するモデル⁵⁾では, 斜面長, 斜面幅を単位長さで考えており, 各セルの流出量 Q は, 計算の結果得られる単位斜面長単位斜面幅流量 q に斜面長 L , 斜面幅 B を乗じたものである. したがって, どの分解能でも同じようにピーク到達時刻の遅れなどの誤差が発生する.


ピーク到達時のピーク流量の超過が, 特に分解能 250 m で目立つことについては以下のように説明できる. 分解能 250 m は 1つのセルのみからなる流域であり, 1つのセル内ではどの分解能でも同様にピーク流量の超過がみられるものと推察される. しかし, 先述のように各セルの流出量 Q は, すなわち $q \times L \times B$ であるから, 分解能 250 m ではよく目立ち, 分解能 50 m では各セルのピーク到達時刻が異なるため, 目立たなくなったものと推察される.



(a) 50-m resolution



(b) 125-m resolution



(c) 250-m resolution

Figure 5.13 Theoretical and simulated hydrographs (node 10).






Figure 5.14 Theoretical and simulated hydrographs (node 2).









Figure 5.15 Theoretical and simulated hydrographs (node 4).



(a) 50-m resolution




(b) 125-m resolution




(c) 250-m resolution


Figure 5.16 Theoretical and simulated hydrographs (node 6).



(a) 50-m resolution




(b) 125-m resolution




(c) 250-m resolution


Figure 5.17 Theoretical and simulated hydrographs (node 8).



(a) 50-m resolution



(b) 125-m resolution



(c) 250-m resolution

Figure 5.18 Theoretical and simulated hydrographs (node 15).

5.4 矢田川流域への適用

5.4.1 水文資料の整理

水位記録

本章では、観測流量として矢田川流域の下流端に位置する瀬古水位観測所（建設省）の以下の水位記録を用いる⁶⁾。1ステップは20分である。

- Flood 1 : 1985 年 6 月 29 日 9 時 00 分から 7 月 1 日 18 時 00 分 ; 172 ステップ
- Flood 2 : 1987 年 9 月 24 日 9 時 00 分から 9 月 25 日 22 時 00 分 ; 112 ステップ
- Flood 3 : 1988 年 6 月 27 日 6 時 00 分から 6 月 28 日 11 時 00 分 ; 88 ステップ
- Flood 4 : 1988 年 9 月 20 日 3 時 00 分から 9 月 21 日 9 時 00 分 ; 91 ステップ
- Flood 5 : 1988 年 9 月 24 日 9 時 00 分から 9 月 26 日 9 時 00 分 ; 145 ステップ
- Flood 6 : 1989 年 9 月 2 日 9 時 00 分から 9 月 4 日 9 時 00 分 ; 145 ステップ
- Flood 7 : 1989 年 9 月 18 日 16 時 00 分から 9 月 20 日 16 時 00 分 ; 145 ステップ

観測流量の算定

瀬古水位観測所では、1985 年から 1988 年の水位流量曲線（水位 $H(m)$ と流量 $Q(m)$ の関係を示す曲線；HQ 曲線）が得られており、水位記録から観測流量を算定できる。

瀬古水位観測所における各年の HQ 曲線は以下のようなものである⁶⁾。

- 1985 年

$$\begin{aligned} Q &= 80.30 (H - 0.89)^2 & H < 1.52 \\ Q &= 30.71 (H - 0.51)^2 & 1.52 \leq H < 3.48 \\ Q &= 71.41 (H - 1.53)^2 & 3.48 \leq H \end{aligned} \quad (5.4)$$

- 1986 年

$$\begin{aligned} Q &= 61.63 (H - 0.88)^2 & H < 1.782 \\ Q &= 30.71 (H - 0.51)^2 & 1.78 \leq H < 3.48 \\ Q &= 71.41 (H - 1.53)^2 & 3.48 \leq H \end{aligned} \quad (5.5)$$

- 1987 年

$$\begin{aligned} Q &= 59.30 (H - 0.88)^2 & H < 1.84 \\ Q &= 30.71 (H - 0.51)^2 & 1.84 \leq H < 3.48 \\ Q &= 71.41 (H - 1.53)^2 & 3.48 \leq H \end{aligned} \quad (5.6)$$

Table 5.1 Gozaisyo radar system characteristics.

位置	三重県三重郡菰野町大字菰野
緯度・経度	北緯 35 度 01 分 03 秒 東経 136 度 25 分 40 秒
空中線標高	1218 m
仰角	0.3 度 (1987 年以降, それ以前は 0.8 度)
観測期間	1983 年 4 月～
グランドクラッタ処理方式	MTI 方式, 減算方式のいずれか選択

● 1988 年

$$Q = 62.10 (H - 0.87)^2 \qquad H < 1.74$$
$$Q = 29.96 (H - 0.49)^2 \qquad 1.74 \leq H < 3.36$$
$$Q = 58.32 (H - 1.30)^2 \qquad 3.36 \leq H$$

(5.7)

ただし, 1989 年は HQ 曲線が確定していないので 1988 年の HQ 曲線 ((5.7) 式) を用いる.

レーダー雨量記録

対象流域は, 建設省御在所レーダーシステムの観測範囲内に位置している. レーダーから対象流域をカバーするレーダーメッシュの最内側までの距離は 48 km, 同じく最遠端までの距離は 75 km であり, これは定量観測範囲内であると考えられる. 御在所レーダー局の諸元を Table 5.1に示す⁶⁾.

本研究では, 以下のレーダー雨量記録を用いた⁶⁾. 1 ステップは 20 分である.

- Flood 1 : 1985 年 6 月 29 日 12 時 00 分から 7 月 1 日 4 時 00 分 : 120 ステップ
- Flood 2 : 1987 年 9 月 24 日 22 時 00 分から 9 月 25 日 9 時 00 分 : 33 ステップ
- Flood 3 : 1988 年 6 月 27 日 15 時 00 分から 6 月 28 日 3 時 00 分 : 36 ステップ
- Flood 4 : 1988 年 9 月 20 日 7 時 00 分から 9 月 20 日 15 時 00 分 : 24 ステップ
- Flood 5 : 1988 年 9 月 24 日 1 時 00 分から 9 月 25 日 18 時 00 分 : 123 ステップ
- Flood 6 : 1989 年 9 月 2 日 9 時 00 分から 9 月 4 日 1 時 00 分 : 120 ステップ
- Flood 7 : 1989 年 9 月 18 日 15 時 00 分から 9 月 20 日 4 時 00 分 : 111 ステップ

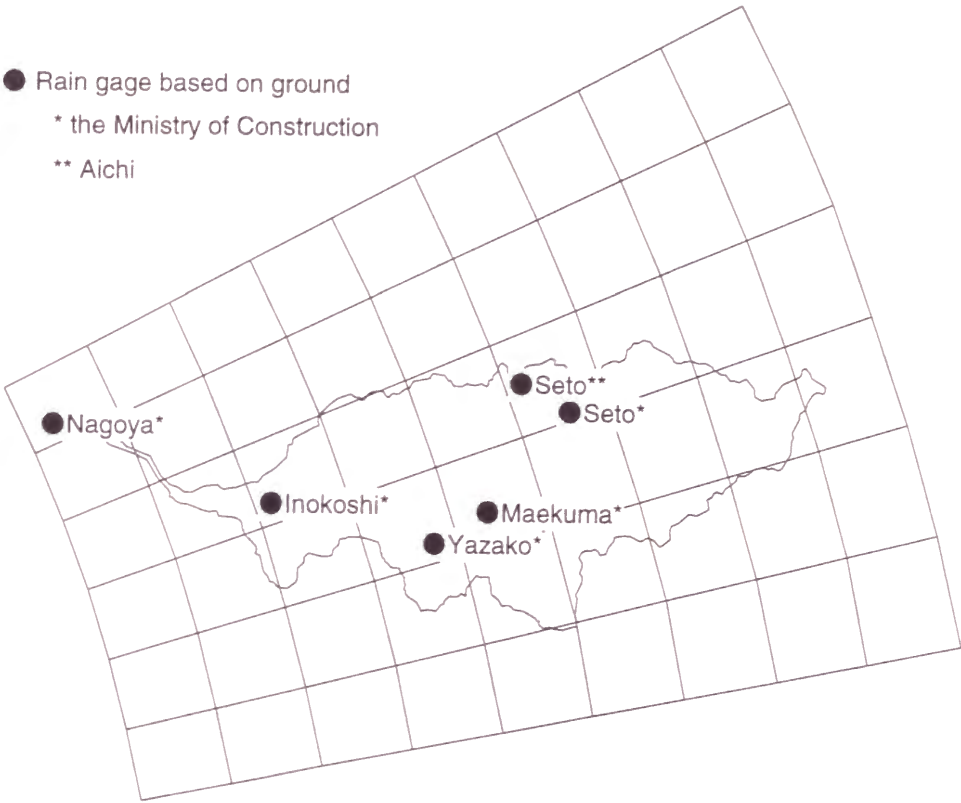


Figure 5.19 Location of radar mesh and 6 rain gages.

地上雨量記録

名古屋 (建), 猪子石, 瀬戸 (建), 瀬戸 (県), 岩作, 前熊の 6 観測所の地上雨量記録を用いる. 20 分間雨量の形で雨量記録を読みとり, 整理したものを地上雨量とした. ただし, 雨量データによっては 20 分間雨量を読みとることが困難な形式のものがあ, それらについては 30 分間雨量を読みとり, 比例配分で 20 分間雨量とした. 本研究で用いた地上雨量は, レーダー雨量の時間ステップと同じとした.

Figure 5.19にレーダー雨量計のメッシュと地上雨量観測所の位置関係を示す.

5.4.2 雨量の空間分布の考慮

レーダー雨量データを用いて, 空間的に分布した雨量を分布型流出モデルの入力データとして用いることを考える. レーダー雨量計によって観測された雨量 (R_R) と, 地上の雨量計で観測された雨量 (R_G) とは, 種々の原因で異なる. 流出計算に必要なのは地上雨量なので, 地上雨量データを用いてレーダー雨量データを補正し, この差異を極力小さくするようにする.

名古屋 (建), 猪子石, 岩作, 前熊の 4 地点における地上雨量データ及び瀬戸 (建) と瀬

戸(県)の地上雨量データの平均値とその直上にあるレーダーメッシュ区画のレーダー雨量との回帰関係から、流域内の全てのレーダーメッシュ区画における地上雨量(R_{RG})を推定する。

各セルへの降雨は、

1. レーダー雨量：各セルの直上のレーダーメッシュ区画の R_{RG}
2. 流域平均雨量： R_{RG} の面積平均値

の2通りを考える。

流域平均雨量に、レーダー雨量の面積平均値を用いた理由は、雨量の空間分布を考慮した場合と考慮しない場合の比較をする際に、2通りの入力降雨形式間で総降雨量が変わらないようにするためである。

5.4.3 有効雨量の算定

有効雨量を算定するために、雨水保留量曲線を用いる。これは降雨が継続してる以下雨量が増加するに伴い、流域内に保留流されて直接流出しない雨水量すなわち保留量の増分は漸減し、やがて累加保留量はある限界値に近づくのではないかとこの考え方に基づいたものである⁷⁾。この方法に従い、Flood 1 から Flood 7 について、総降雨量から直接流出量を減じることにより流域保留量を求め、その値を各総降雨量に対してプロットし雨水保留量曲線を得た。直接流出量は、H-Q 曲線を用いて得られたハイドログラフ (Figure 5.20) を片対数紙にプロットし (Figure 5.21)、ハイドログラフの立ち上がりから流出の終わりまでを直線で結び、その直線より下を基底流出成分、上を直接流出成分として求めた。

Figure 5.22に得られた雨水保留量曲線を示す。Figure 5.22より、降雨期間中一定率損失を仮定して、地上雨量に流出係数 $f = 0.5$ を乗じることにより有効雨量を求めた。

5.4.4 河道幅一定モデル (Model A) への適用

本研究で提唱したセル分布型モデルにおいて、5.3.4項によるモデル定数決定法を用いて計算を行う。5.3.4項では、流域の等価粗度を土地利用を用いて決定し、流域の土地利用は、Landsat/TM 画像の分類結果と近似河道データを用いて決定している。このとき、近似河道データにおいて河道とされているセルは、河川という土地利用クラスとしている。

したがって、流域全体は、森林 (Forest)、水田 (Paddy)、草地 (Grass)、都市域 (Urban)、水域 (Water)、河川 (River) という6クラスに分類され (Plate 5.19)、それぞれの土地利用クラスごとに等価粗度を与えられる。

このとき、河川に分類されたセルも他の分類クラスのセルと同様に、分解能 50 m のモデルなら、斜面長 50 m、斜面幅 50 m の部分流域と仮定する。すなわち、分解能 50 m のモデルなら、河道幅は常に 50 m ということになる。これを Model A と呼ぶこととする。




Figure 5.20 Observed hydrograph.




Figure 5.21 Direct flow and base flow of observed hydrograph.




Figure 5.22 Relationship between cumulated rainfall and retention.

モデル定数 (等価粗度) の感度分析

1987年9月24日から25日にかけての豪雨 (Flood 2) に対して計算を行う。観測ハイドログラフは、H-Q 曲線を用いて水位記録から算定した。観測ハイドログラフのピークは、ピーク流量 $334.4 \text{ m}^3/\text{s}$ と、その1時間後に $328.4 \text{ m}^3/\text{s}$ が存在する。

等価粗度を土地利用ごとにそれぞれ変え、計算を行った。それぞれの Case における等価粗度を Table 5.2 に示す。Case 1 では、等価粗度を参考値の組み合わせ (森林 0.7, 水田 2.0, 草地 0.4, 都市域 0.1, 水域 2.0, 河川 0.05) として解析を行った (Figure 5.23)。分解能 50 m では3時間程度、分解能 150 m では6時間程度、分解能 250 m では9時間程度ピーク時刻に遅れが生じた。そこで、等価粗度を、都市域 0.05, 河川 0.01 として解析を行った (Case 2; Figure 5.24)。分解能 50 m では、ピーク時刻の遅れは60分、分解能 150 m では、ピーク時刻の遅れは80分程度に改善された。分解能 250 m では、Case 1 に比べれば改善されているが、まだ2時間ピーク時刻が遅れていた。Case 2 の等価粗度に対して、都市域のみ 0.01 と変えて計算を行った (Case 3; Figure 5.25) が、分解能 50 m, 150 m, 250 m のいずれにおいても Case 2 に比べてピーク時刻が20分早くなったに止まった。同じく Case 2 に対して、河川のみ 0.005 として計算を行った (Case 4; Figure 5.26)。分解能 50 m では、観測ハイドログラフとのピーク時刻の遅れは40分と Case 3 と同じだが、ピーク流量は Case 3 の $263.3 \text{ m}^3/\text{s}$ から $274.3 \text{ m}^3/\text{s}$ と増え、観測ハイドログラフ ($334 \text{ m}^3/\text{s}$) に近づいた。分解能 150 m では、ピーク時刻の遅れは20分となり、観測ハイドログラフに極めて近づいた。分解能 250 m では、観測ハイドログラフと比較してピーク時刻の遅れは40分程度であり、Case 3 に比べてかなり改善された。

Case 3 は、Case 2 に対して、都市域の等価粗度を $1/5$ にした結果であり、Case 4 は、

Table 5.2 Roughness coefficient for each case.

	Forest	Paddy	Grass	Urban	Water	River
Case 1	0.7	2.0	0.4	0.1	2.0	0.05
Case 2	0.7	2.0	0.4	0.05	2.0	0.01
Case 3	0.7	2.0	0.4	0.01	2.0	0.01
Case 4	0.7	2.0	0.4	0.05	2.0	0.005
Case 5	0.5	1.5	0.3	0.05	1.5	0.005
Case 6	0.5	1.5	0.3	0.05	1.5	0.003
Case 7	0.5	1.5	0.3	0.05	1.5	0.001

Case 2 に対して、河川の等価粗度を $1/2$ にした結果である。Figure 5.25 と Figure 5.26 を比較すると、Case 4 の方が等価粗度を変えた事によるハイドログラフの改善が著しい。河川の等価粗度は、都市域の等価粗度を変えることに比べて、解析結果に与える影響が大きいことが分った。

Case 1 から Case 4 では、ピーク流量があまり適合しておらず、河川、都市域以外の等価粗度を小さくする必要があると思われる。そこで、Case 4 に対して森林、水田、草地、水域の等価粗度を参考値より小さくして (森林: $0.7 \rightarrow 0.5$, 水田: $2.0 \rightarrow 1.5$, 草地: $0.4 \rightarrow 0.3$, 水域: $2.0 \rightarrow 1.5$) 計算を行った。都市域の等価粗度は、Case 4 と同じ 0.05 とした。

このようにした上で、河川の等価粗度を 0.005 として計算を行った (Case 5; Figure 5.27)。分解能 50 m では、ピーク時刻は観測ハイドログラフより20分遅く、ピーク流量は $319.2 \text{ m}^3/\text{s}$ と Case 4 に比べて増加し、観測ハイドログラフに近づいた。分解能 150 m では、ピーク時刻は Case 4 と同じく観測ハイドログラフより20分遅いが、ピーク流量は $299.8 \text{ m}^3/\text{s}$ と Case 4 に比べて増加し、観測ハイドログラフに近づいた。分解能 250 m では、ピーク時刻は観測ハイドログラフより40分遅く、ピーク流量は $273.6 \text{ m}^3/\text{s}$ と Case 4 に比べて増加しているが、まだ観測ハイドログラフよりかなり少ない。

次に、河川の等価粗度を 0.003 として計算を行った (Case 6; Figure 5.28)。分解能 50 m では、ピーク時刻は観測ハイドログラフより20分遅く、ピーク流量は $324.3 \text{ m}^3/\text{s}$ と Case 5 に比べて増加し、さらに観測ハイドログラフに近づいた。分解能 150 m では、ピーク時刻の遅れはなく、ピーク流量は $326.6 \text{ m}^3/\text{s}$ と Case 5 に比べて増加し、極めて観測ハイドログラフに近づいた。分解能 250 m では、ピーク時刻は観測ハイドログラフより20分遅く、ピーク流量は $306.4 \text{ m}^3/\text{s}$ と Case 5 に比べて増加し、観測ハイドログラフに近づいた。

最後に、河川の等価粗度を 0.001 として計算を行った (Case 7; Figure 5.29)。分解能 50 m では、ピーク時刻は観測ハイドログラフによく適合し、ピーク流量は、 $332.6 \text{ m}^3/\text{s}$ と観測ハイドログラフに最もよく適合している。分解能 150 m では、ピーク時刻は観測ハイドログラフより20分早い。ピーク流量は、 $362.5 \text{ m}^3/\text{s}$ と観測ハイドログラフのピーク流量を大きく上回っている。分解能 250 m では、ピーク時刻は観測ハイドログラフより20分早い。

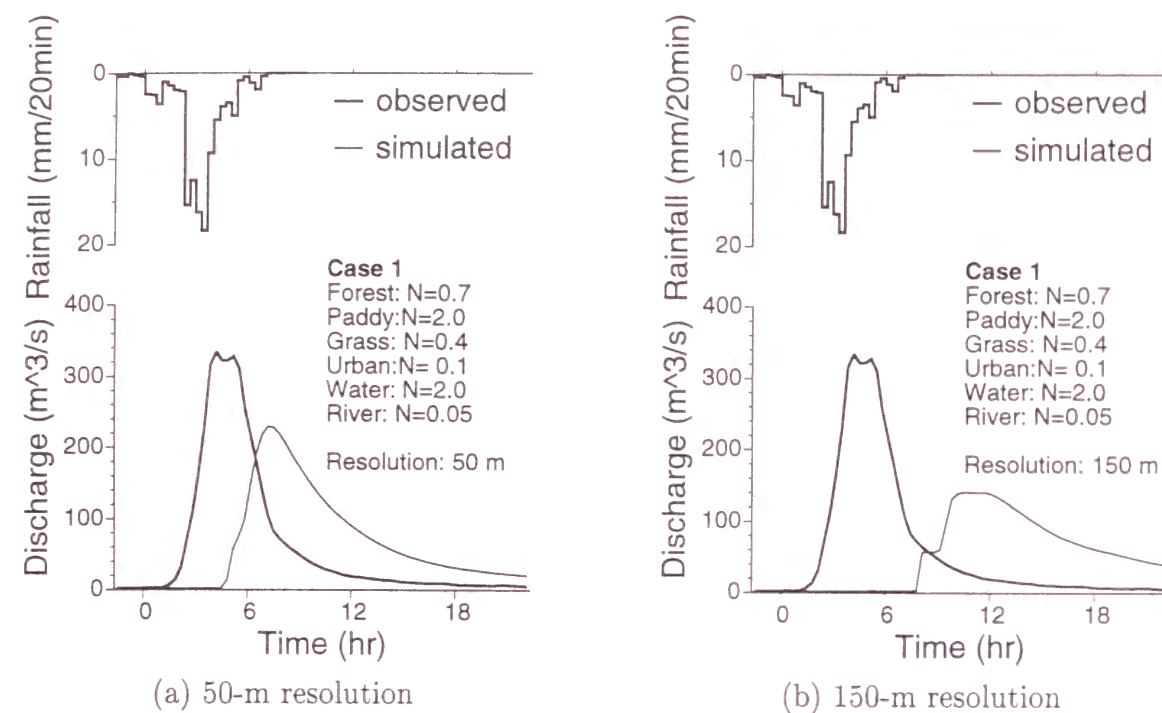
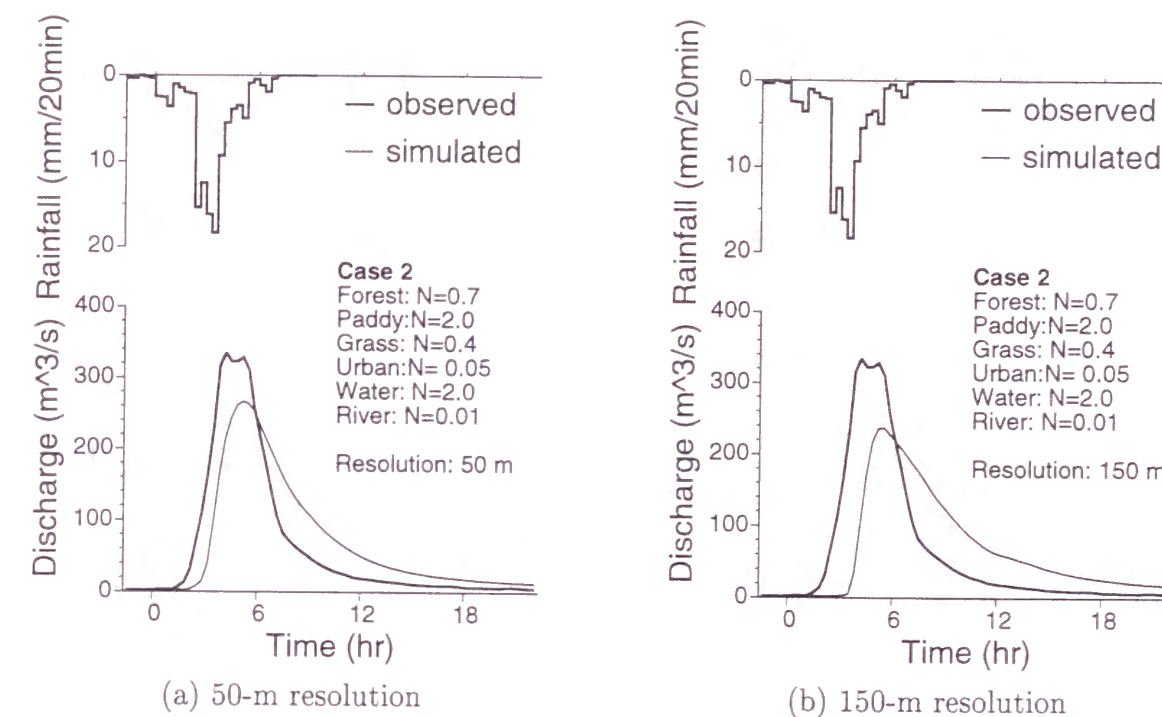


Figure 5.23 Observed and simulated hydrographs (Case 1).



(c) 250-m resolution

Figure 5.24 Observed and simulated hydrographs (Case 2).


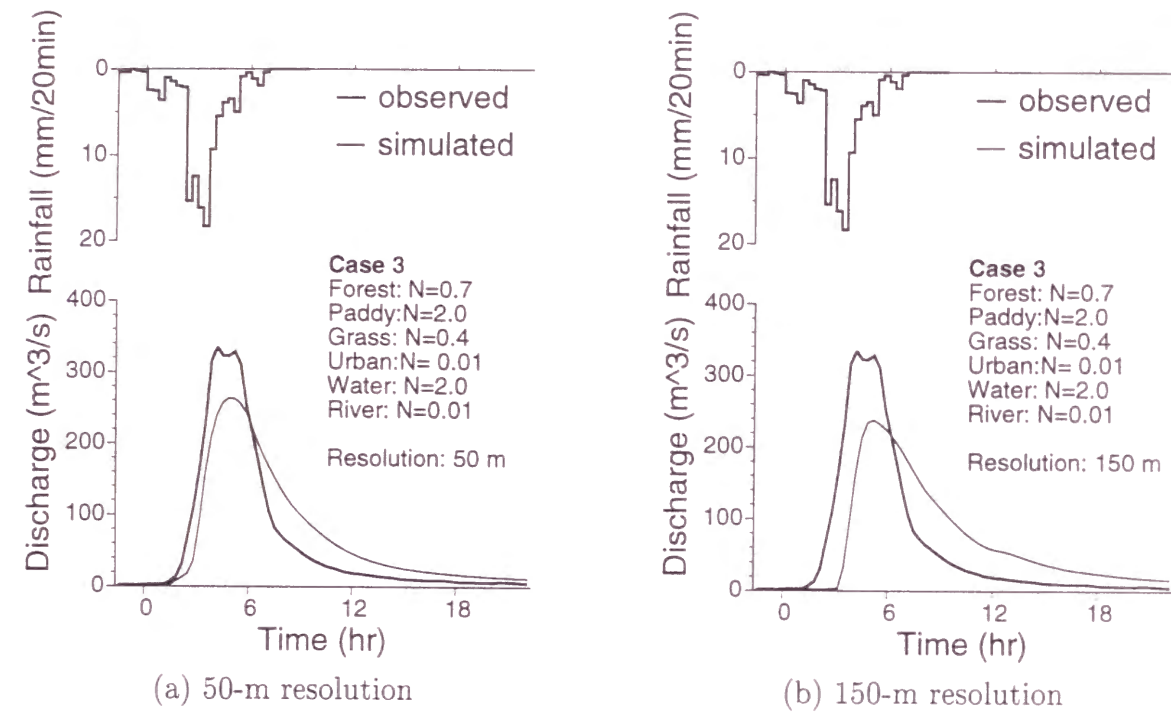


Figure 5.25 Observed and simulated hydrographs (Case 3).


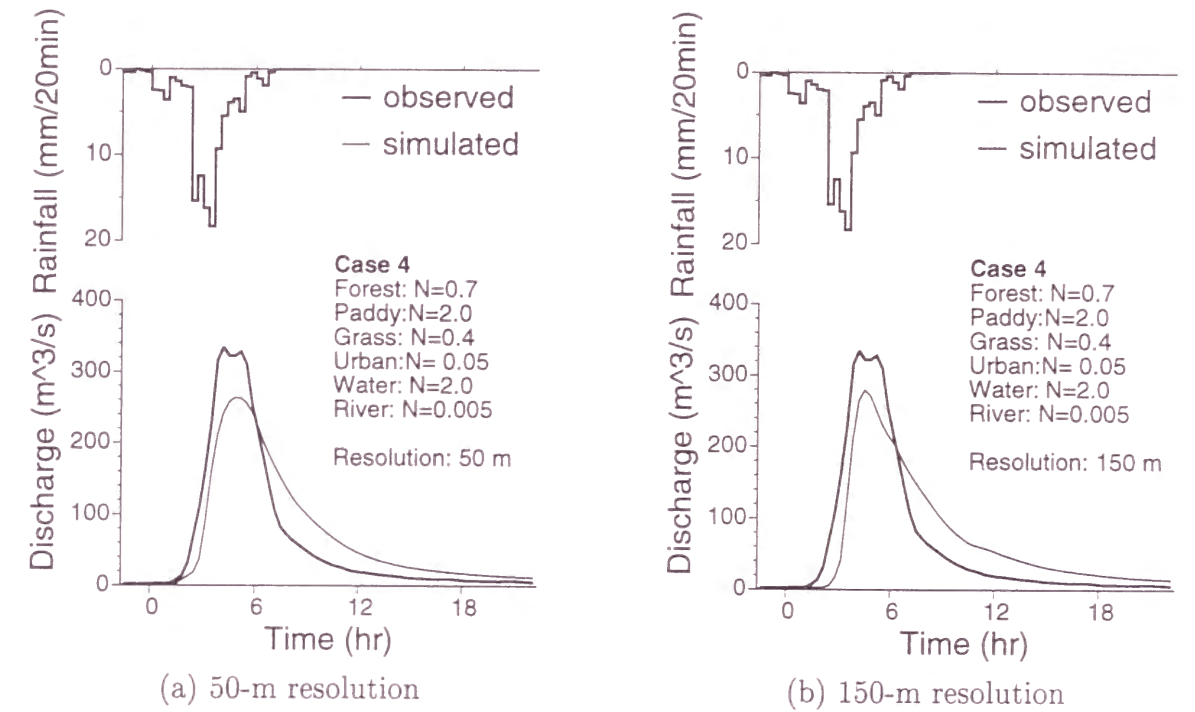


Figure 5.26 Observed and simulated hydrographs (Case 4).


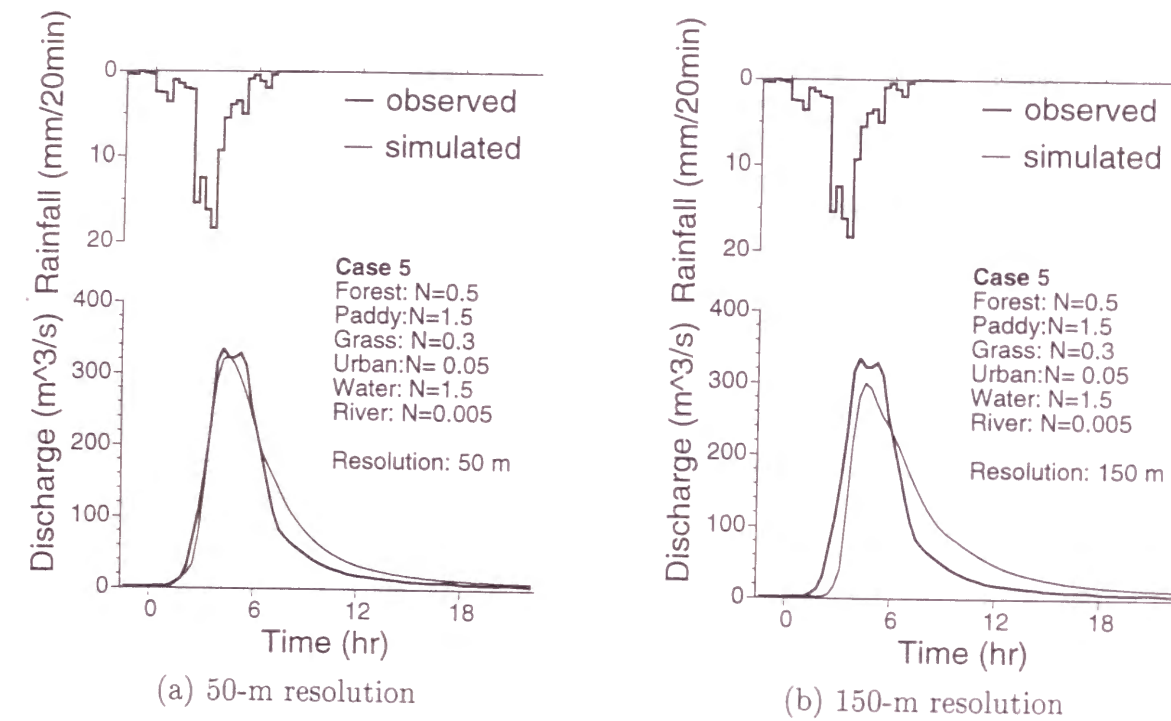


Figure 5.27 Observed and simulated hydrographs (Case 5).


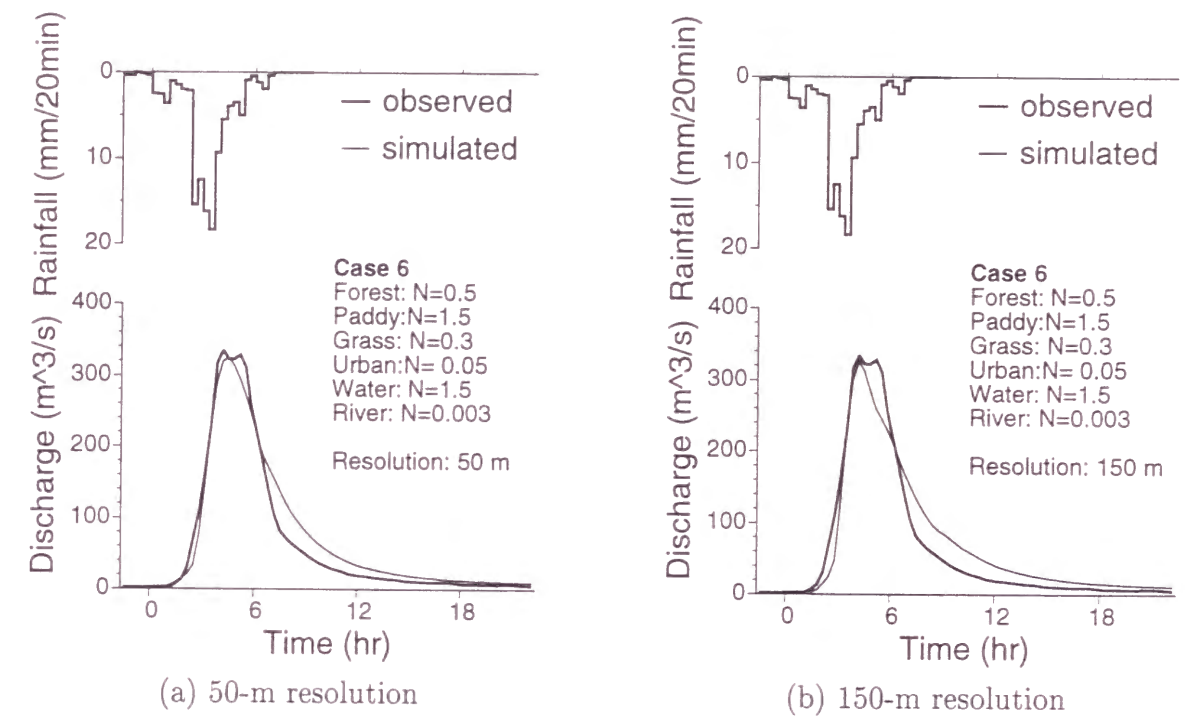


Figure 5.28 Observed and simulated hydrographs (Case 6).

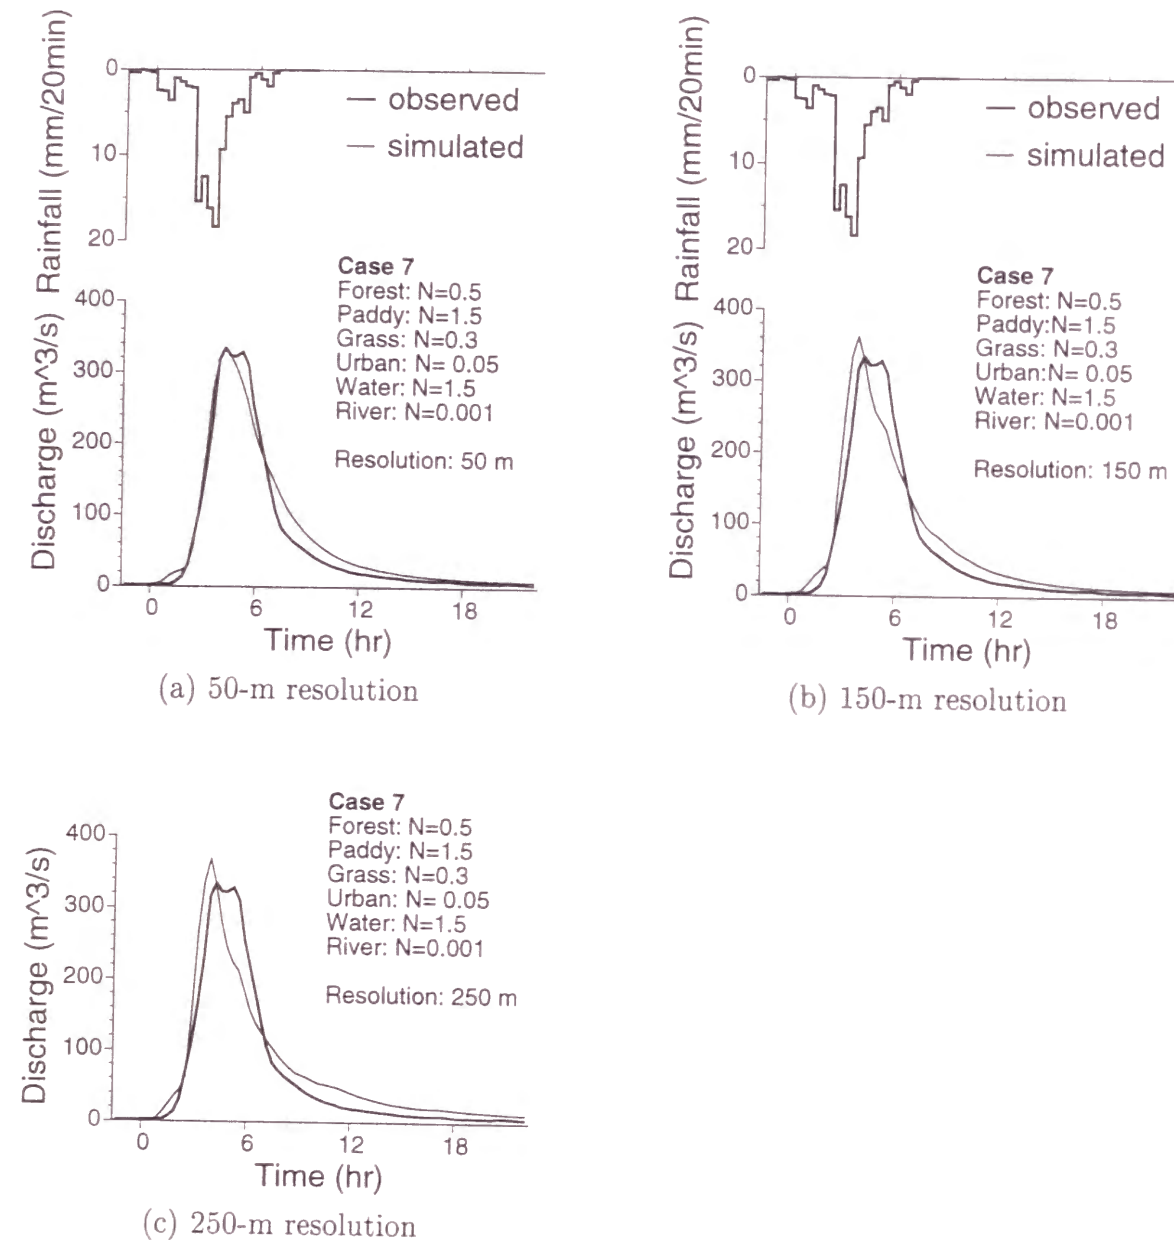


Figure 5.29 Observed and simulated hydrographs (Case 7).

ピーク流量は、 $368.8 \text{ m}^3/\text{s}$ と観測ハイドログラフのピーク流量を大きく上回っている。河川の等価粗度を0.01から0.001の範囲で変えて計算した結果、次のことが言える。

- 分解能150 m, 250 mでは、河川の等価粗度を0.005から0.001の範囲で変化させると、0.005ではピーク流量が少なく、ピーク時刻も遅れていたが、0.001ではピーク流量は観測ハイドログラフを上回り、ピーク時刻も早くなり、計算ハイドログラフの形状が大きく変化する。また、そのハイドログラフの形状の変化は分解能250 mの方が著しい。
- 分解能50 mでは、河川の等価粗度を0.005から0.001の範囲で変化させると、徐々に計算ハイドログラフは改善された。しかし、分解能250 mのような計算ハイドログラフの形状の著しい変化は見られない。

雨量の空間分布の考慮

Case 7では雨量の空間分布を考慮していたが、これに流域平均雨量を与えた場合の解析結果をFig. 5.30に示す(Case 7')。Fig. 5.29と比較すると、いずれの分解能であってもFig. 5.30の方がピーク流量が若干多く、観測ハイドログラフのピーク流量を上回っている。

Fig. 5.31に、ハイドログラフのピーク付近の雨量の空間分布の時間変化を示す。(a), (b), (c), (d)の順に20分毎の雨量の空間分布を示している。白っぽい方が雨量強度が強く、黒っぽい方が雨量強度が弱い。また、中心付近の対象流域内では、流域外より色を薄くしている。強雨域が下流側から上流側へ移動していく様子が見て取れる。

計算時間について

本研究では、ヒューレッドパッカード社のHP712を用いて計算を行った。ソースプログラムはC言語で書かれ、UNIX標準のCコンパイラを用いた。24時間分の流出を計算するために要したCPU時間は、Case 7'において分解能50 mでは40572秒、分解能150 mでは3076秒、分解能250 mでは959秒であった。すなわち、雨水の動きを流域のあらゆる場所で逐次計算するセル分布型流出モデルを50 mの空間分解能で用いると、 110 km^2 程度の領域であれば、24時間分の計算が11時間程度の計算時間を要することが示された。

Fig. 5.30に、各計算ステップ(20分)における計算時間を点線で示す。流量が多いステップほど、計算時間が長い事が分かる。本研究では、kinematic wave法の基礎式((5.1)式, (5.2)式)をLax-Wendroff型の差分スキーム⁵⁾で解き、その計算時間間隔はCourantの条件を満たすように、流量が多いステップほど計算間隔を短くするアルゴリズムとしているので、CPU時間が長くなる。

5.4.5 河道幅考慮モデル(Model B)への適用

河道幅一定モデルに対して、河道幅を考慮したモデルを河道幅考慮モデル(Model B)と呼ぶことにする。河道幅一定モデル(Model A)に対して、河道幅を考慮したモデルをModel B

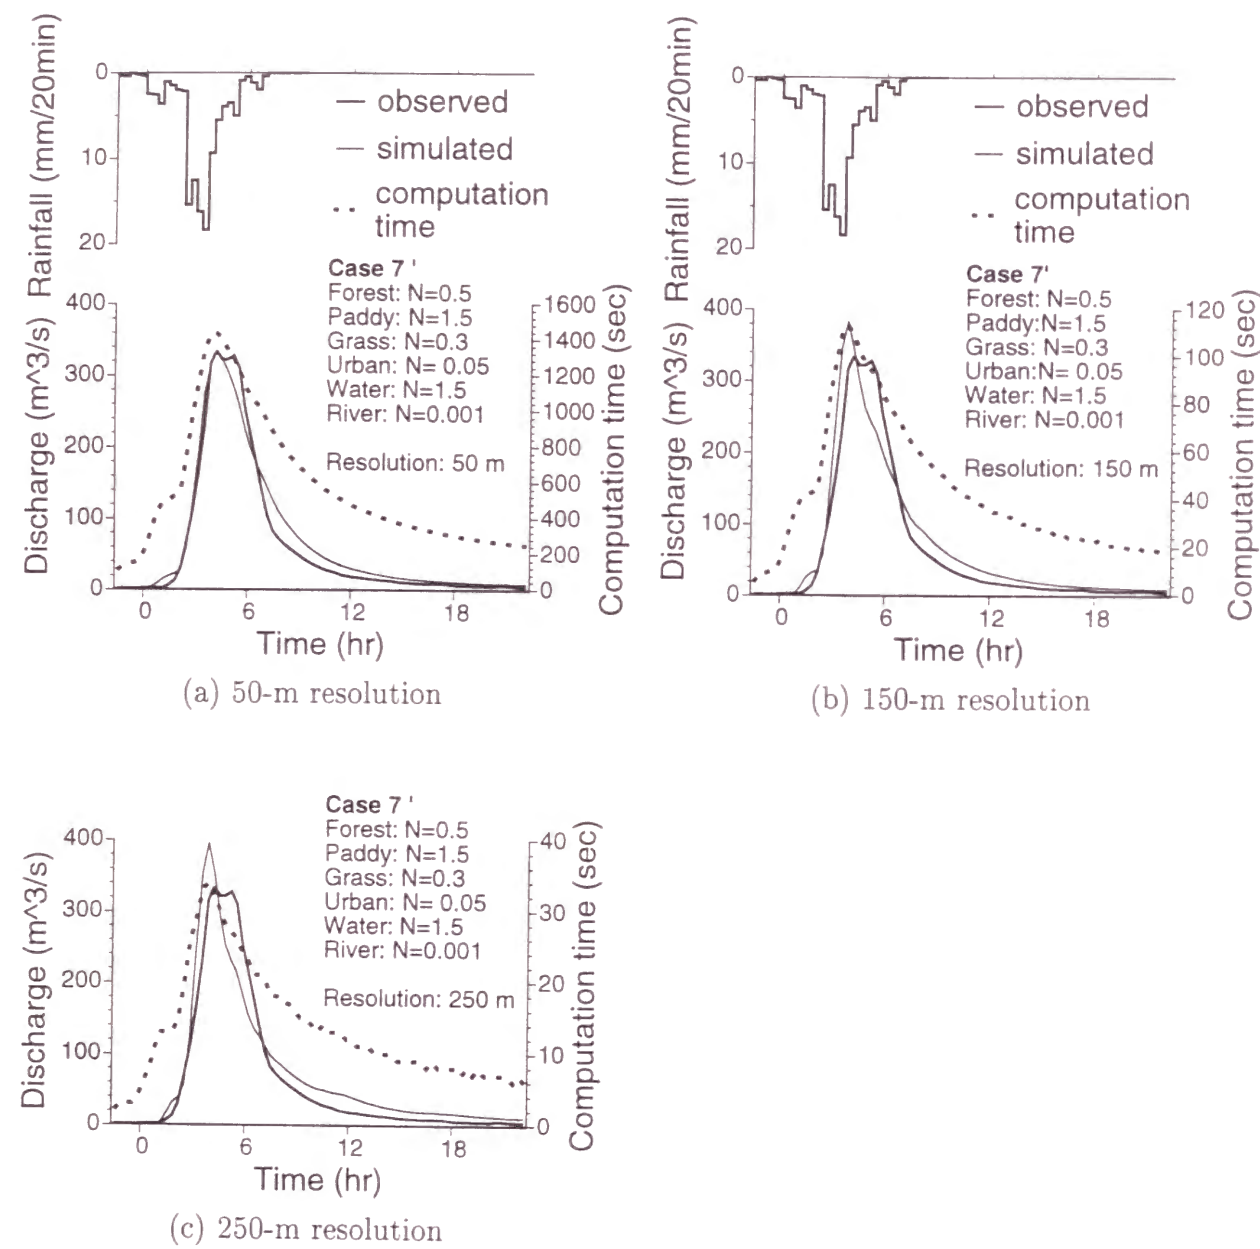


Figure 5.30 Observed and simulated hydrographs with spatially averaged rainfall (Case 7').

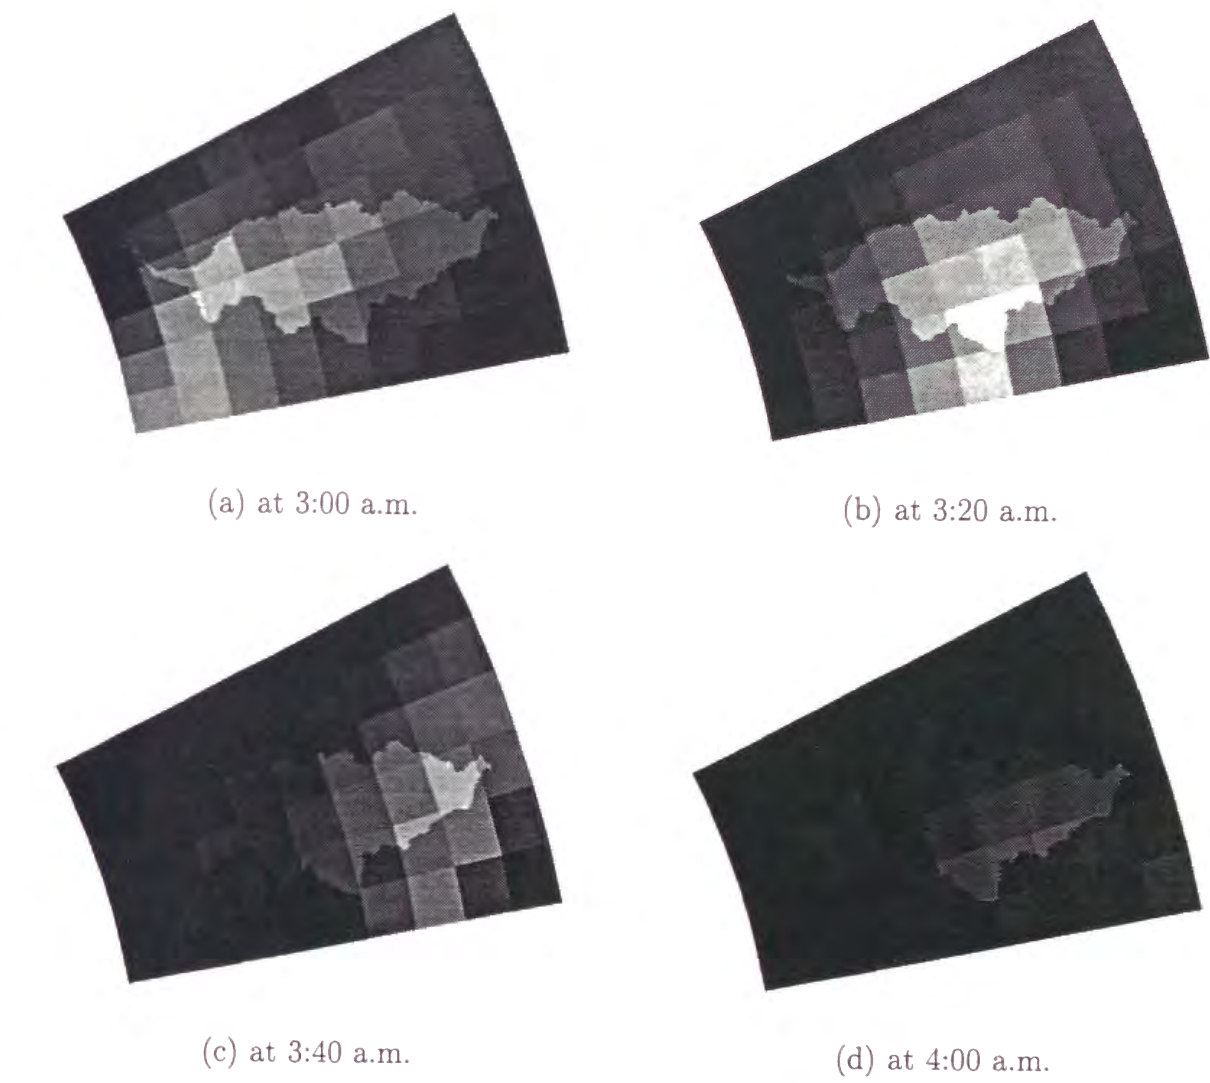


Figure 5.31 Distributions of rainfall at intervals of twenty minutes on Sept. 25, 1987. The rainfall rate is greater in the lighter area (the lightest corresponds to about 60 mm/hr), while less in the darker area.

と呼ぶことにする。細密数値情報の土地利用データ (Plate 5.16) から、近似河道データによって河道とされるセルの河道幅を求めた。ただし、細密数値情報の土地利用データは分解能 10 m のため、河道幅が 10 m 以下となると画像上では視認できなくなる。そのため、近似河道データで河道とされているが、土地利用データから河道幅を入手できなかったセルについては、その河道幅をすべて 5 m とした。

Model B では、河道付近のセル流出計算が他と多少異なる。河道幅が、分解能より狭いセルでは、そのセルへの降雨はすぐに河道に入るものとする。すなわち、分解能 50 m、河道幅 5 m のセルでは、斜面幅 5 m、斜面長 50 m の斜面を仮定し、その斜面への入力、他のセルへの入力と同じ量の降雨があるとする。つまり、あるステップの降雨量が 10 mm/h としたら、分解能 50 m、河道幅 5 m のセルへは、 $10 \times 50/5$ mm/h の降雨が入力となる。

河道幅が、分解能より広いセルでは、そのセルには分解能と同じ面積への降雨だけが入力される。すなわち、分解能 50 m、河道幅 75 m のセルでは、斜面幅 75 m、斜面長 50 m の斜面を仮定し、その斜面への入力、他のセルへの入力と同じ量の降雨があるとする。つまり、あるステップの降雨量が 10 mm/h としたら、分解能 50 m、河道幅 75 m のセルへは、 $10 \times 50/75$ mm/h の降雨が入力となる。

以上のルールによって、河道幅を考慮した流出計算を行う。

モデル定数 (等価粗度) の感度分析

Model A と同様に、Case 1～7 までの等価粗度 (Table 5.2) を与えてハイドログラフを求めた。

Case 1 では、分解能 50 m ではピーク時刻は 3 時間程度遅れ、Model A と同様であった。しかし、分解能 150 m、250 m では、ピーク時刻の遅れは 4 時間程度であり、Model A に比べて極めて向上した (Figure 5.32)。Case 2 では、分解能 50 m ではピーク時刻は 60 分程度遅れ、Model A からの向上はなかった。しかし、分解能 150 m ではピーク時刻の遅れは 40 分、分解能 250 m では 20 分であり、Model A に比べて向上している (Figure 5.33)。Case 3 (Figure 5.34) では、分解能 50 m ではピーク時刻の遅れは 40 分であり、Case 2 より 20 分早くなった。これは、Model A と同じである。分解能 150 m では、ピーク時刻の遅れは 20 分、ピーク流量は $292.4 \text{ m}^3/\text{s}$ 、分解能 250 m では、ピーク時刻の遅れは 20 分、 $295.4 \text{ m}^3/\text{s}$ であり、Model A における Case 3 のハイドログラフからの向上は目立つが、Case 2 (Figure 5.33) からはあまり向上していない。Case 4 (Figure 5.35) では、分解能 50 m では、ピーク時刻の遅れは 40 分と Case 3 と同じだが、ピーク流量は Case 3 の $265.8 \text{ m}^3/\text{s}$ から $273.6 \text{ m}^3/\text{s}$ に向上している。分解能 150 m では、ピーク時刻の遅れはなく、ピーク流量は $316.6 \text{ m}^3/\text{s}$ と Case 3 より向上している。分解能 250 m では、ピーク時刻の遅れはなく、ピーク流量は $330.0 \text{ m}^3/\text{s}$ と Case 3 より観測ハイドログラフ ($334 \text{ m}^3/\text{s}$) に近づいた。

Case 3 と Case 4 の計算ハイドログラフを比較すると、Case 4 の方が Case 2 に対するハイドログラフの改善が著しい。これは、河道幅が一定の Model A と同様の結果であり、河川の等価粗度は、都市域の等価粗度を変えることに比べて、解析結果に与える影響は、河道幅を考慮したモデルにおいても大きいことが分かった。

次に Case 5～7 についても同様に解析した。Case 5 では、分解能 50 m では、ピーク時

Table 5.3 Comparison of peak volumes.

	50-m resolution		150-m resolution		250-m resolution	
	Model A	Model B	Model A	Model B	Model A	Model B
Case 4	274.3	273.6	279.7	316.6	260.8	330.0
Case 5	319.2	316.9	299.8	337.6	273.6	345.5
Case 6	324.3	322.1	326.6	352.2	306.4	368.7
Case 7	332.6	331.7	362.5	367.3	368.8	397.3

刻は 20 分遅れ、ピーク流量は $316.9 \text{ m}^3/\text{s}$ であった。分解能 150 m では、ピーク時刻に遅れは無かった。ピーク流量は $337.6 \text{ m}^3/\text{s}$ であり、観測ハイドログラフ ($334 \text{ m}^3/\text{s}$) を若干上回っている。分解能 250 m では、ピーク時刻に遅れは無かった。ピーク流量は $345.5 \text{ m}^3/\text{s}$ であり、観測ハイドログラフを上回っている。Case 6 では、分解能 50 m では、ピーク時刻は 20 分の遅れ、ピーク流量は $322.1 \text{ m}^3/\text{s}$ であり、Case 5 に比べて向上した。分解能 150 m では、ピーク時刻は観測ハイドログラフより 20 分早く、ピーク流量は $352.2 \text{ m}^3/\text{s}$ と観測ハイドログラフのピーク流量を大きく上回っている。分解能 250 m では、ピーク時刻は観測ハイドログラフより 20 分早く、ピーク流量は $368.7 \text{ m}^3/\text{s}$ と観測ハイドログラフのピーク流量を大きく上回っている。Case 7 分解能 50 m では、ピーク時刻の遅れは無く、ピーク流量は $331.7 \text{ m}^3/\text{s}$ であり、観測ハイドログラフによく適合している。分解能 150 m では、ピーク時刻は観測ハイドログラフより 40 分早く、ピーク流量は $367.3 \text{ m}^3/\text{s}$ と Case 6 のピーク流量をさらに上回っている。分解能 250 m では、ピーク時刻は観測ハイドログラフより 40 分早く、ピーク流量は $397.3 \text{ m}^3/\text{s}$ と Case 6 のピーク流量をさらに上回っている。

Model A と Model B を用いて計算された Case 4～7 のピーク流量を Table 5.3 に示す。分解能 150 m と 250 m では、Model A のピーク流量に比べて、Model B のピーク流量の方が多いことが分かる。これは河道幅を考慮したことによる効果である。Model A では河道幅を分解能と同じ大きさにしていたため、水位は低く、流れが遅かったが、河道幅を考慮することによって、より早く流れることになる。分解能 50 m では、Model A のピーク流量と比べて、Model B のピーク流量は若干ずつ少ない。矢田川の下流域では、河道幅は 50 m を越えている。そのため、モデルに河道幅を考慮すると、下流域では水位が低くなり、流れが若干遅くなると考えられる。

以上より、河道幅をモデルに考慮すると、分解能 50 m では若干流出が遅くなり、分解能 150 m、250 m では流出が早くなり、より実際の流出現象に近くなる。また、河道幅の考慮が計算結果に与える影響は、分解能 250 m が最も大きく、分解能 50 m が最も小さい。

等価粗度ダイヤグラムによる感度分析

森林、水田、草地、都市域、水域、河川の 6 つの土地利用クラスのうち、4 クラスの等価粗度を固定し、2 つのクラスの等価粗度のみを変えてハイドログラフを計算する。計算された

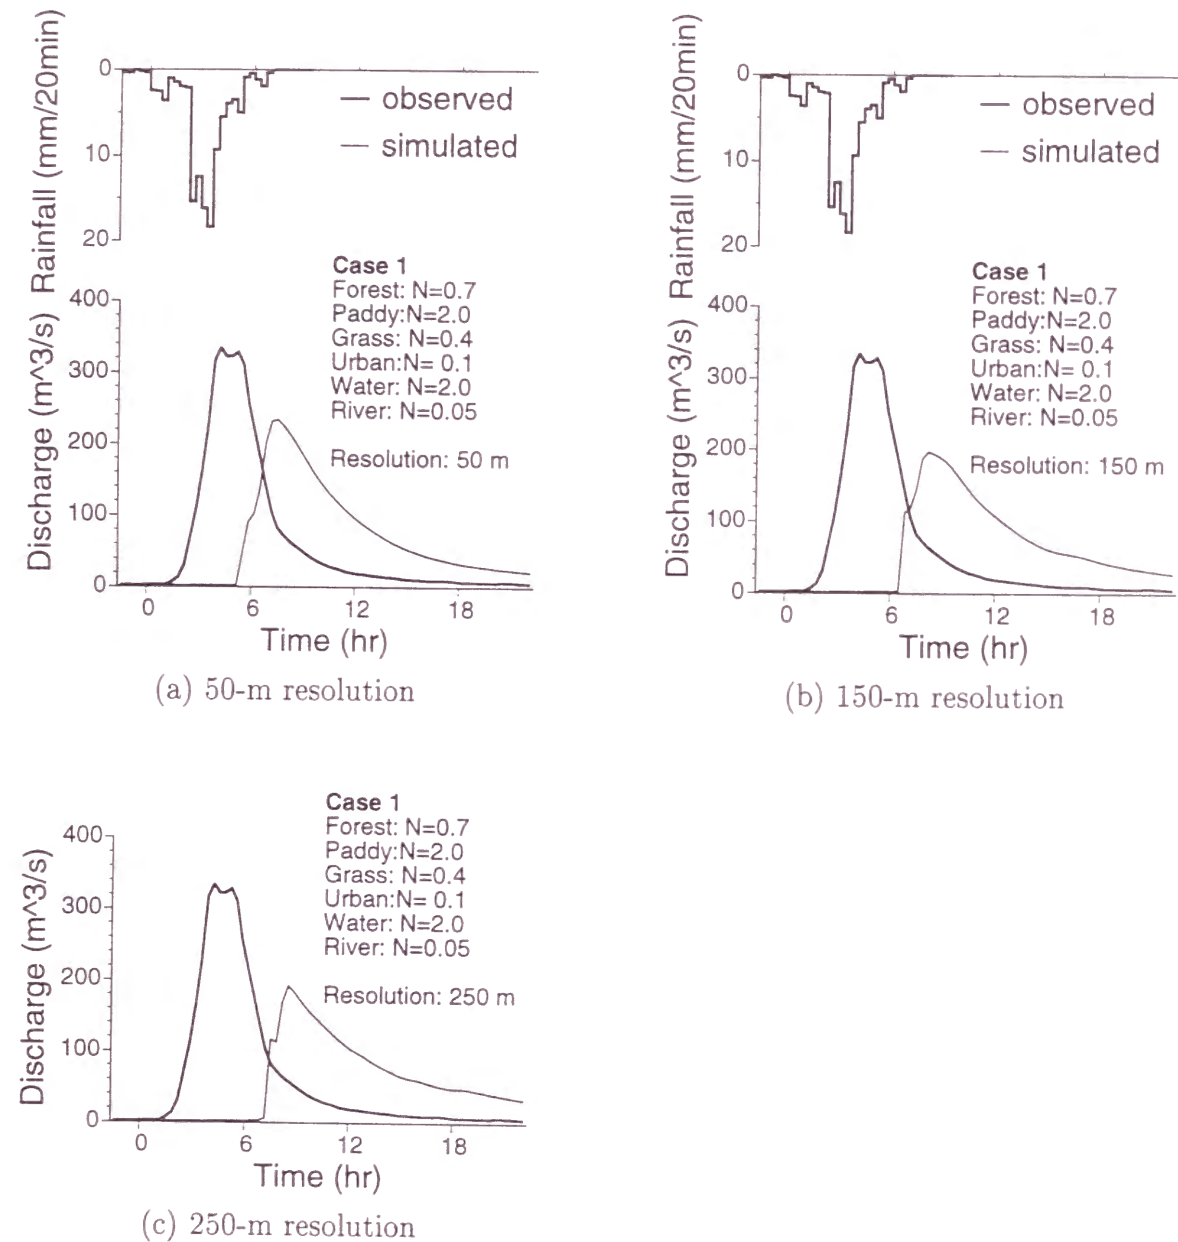


Figure 5.32 Observed and simulated hydrographs (Case 1).

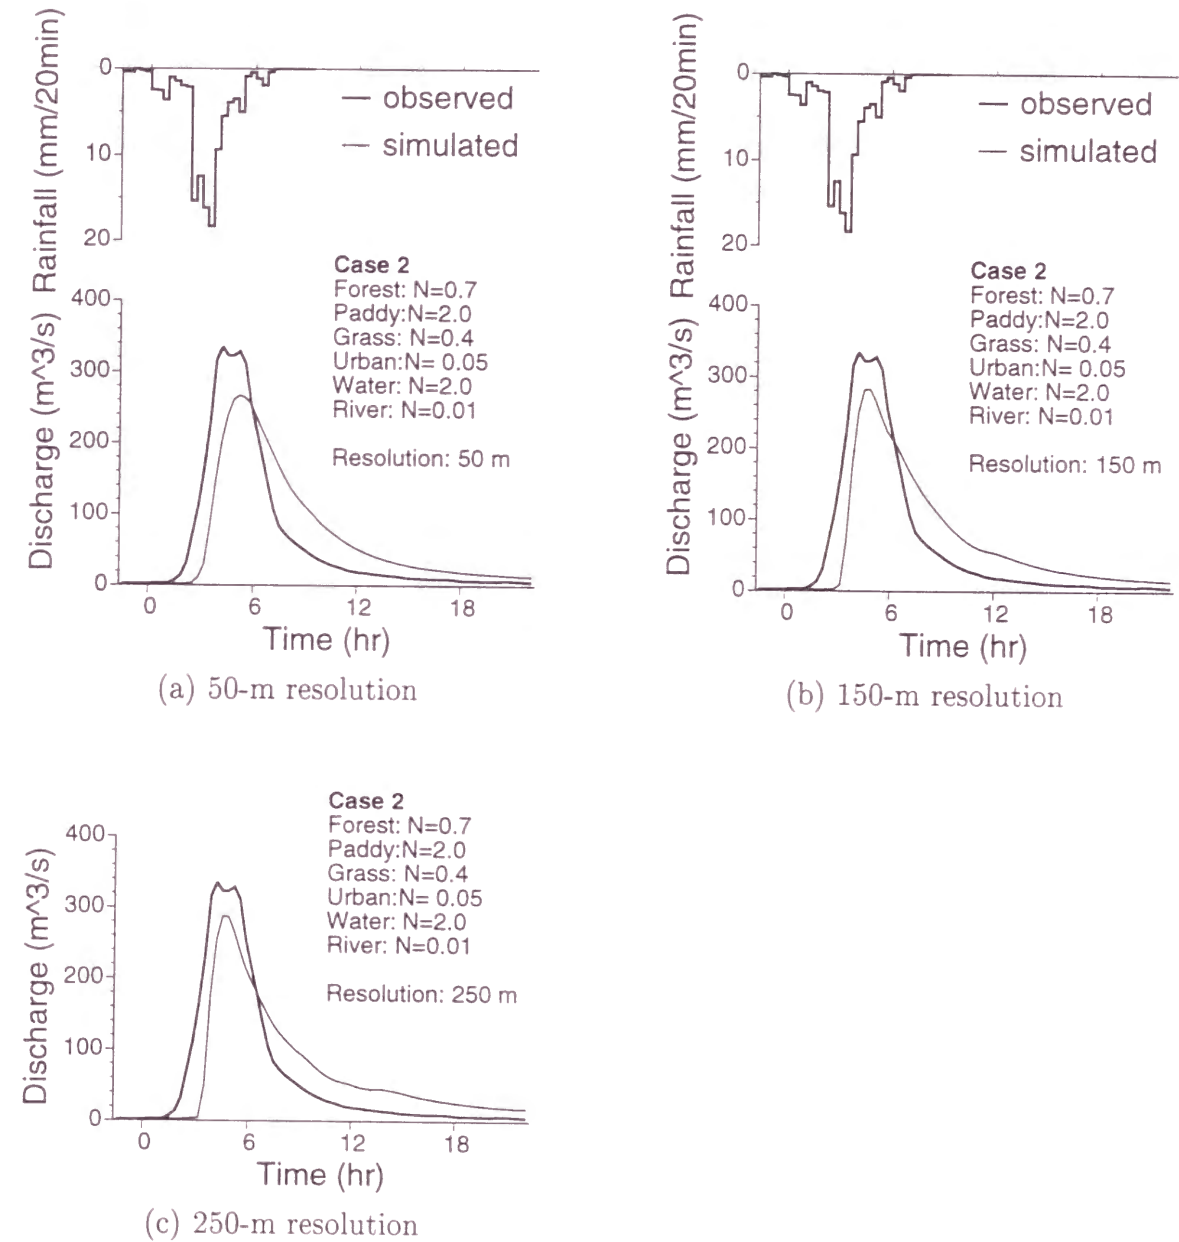


Figure 5.33 Observed and simulated hydrographs (Case 2).


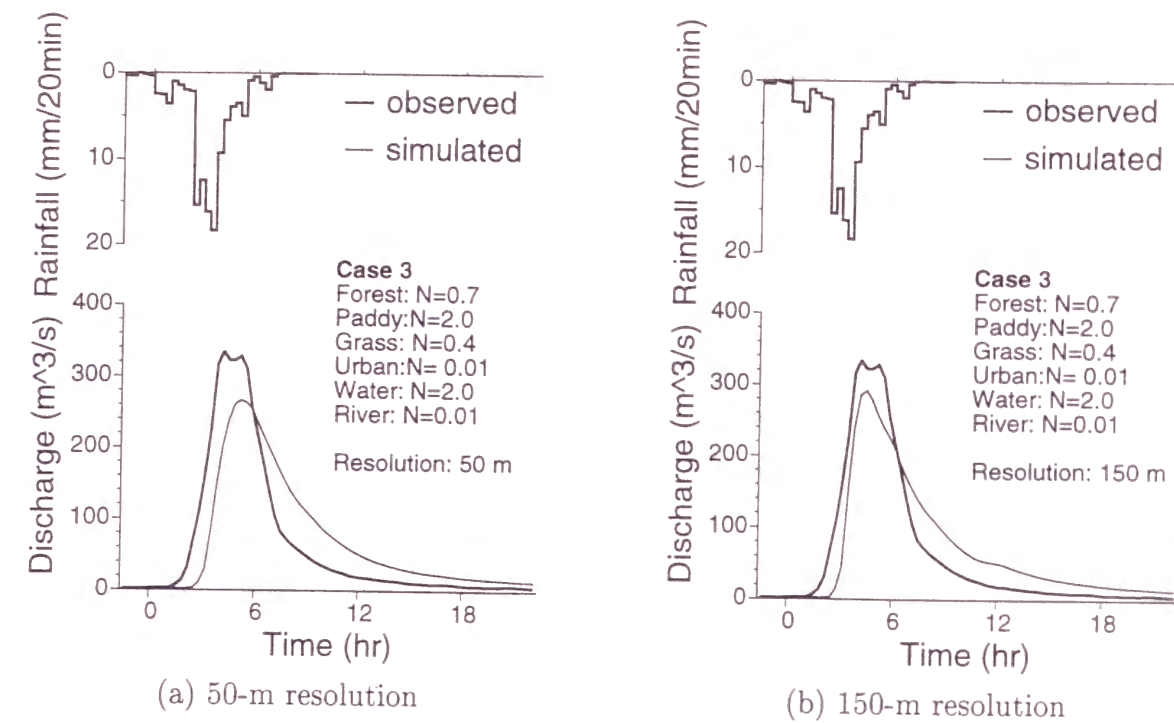


Figure 5.34 Observed and simulated hydrographs (Case 3).


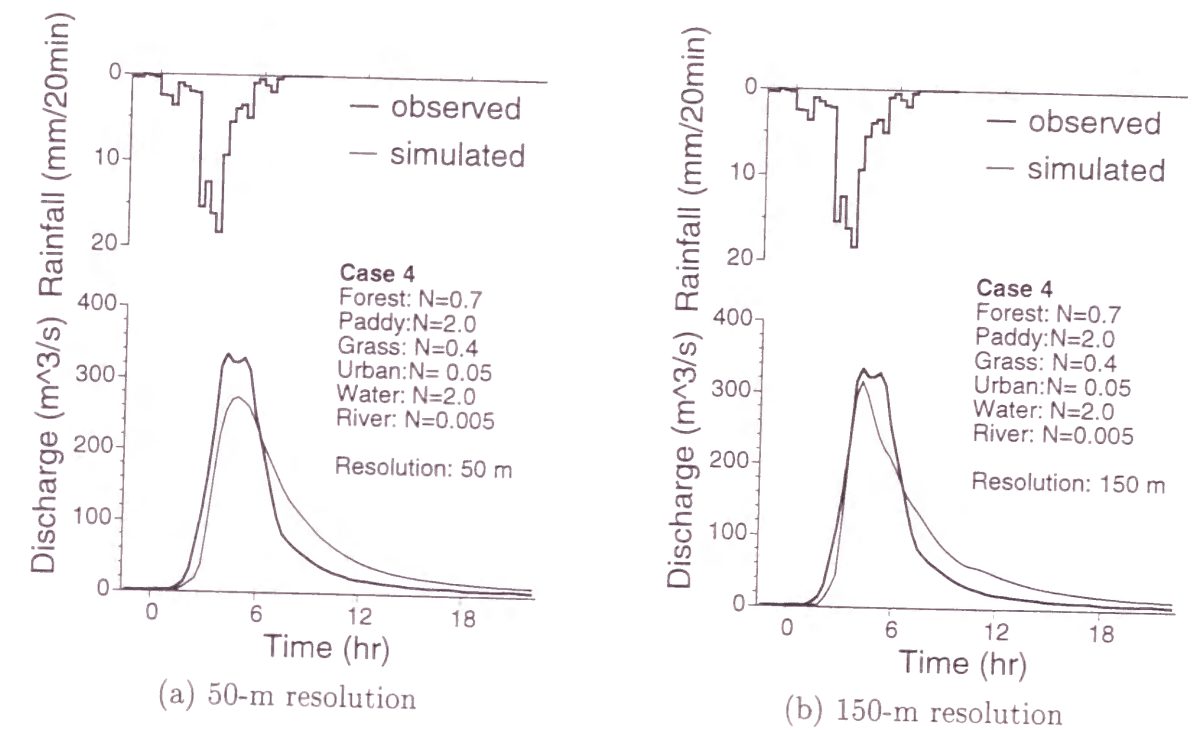


Figure 5.35 Observed and simulated hydrographs (Case 4).

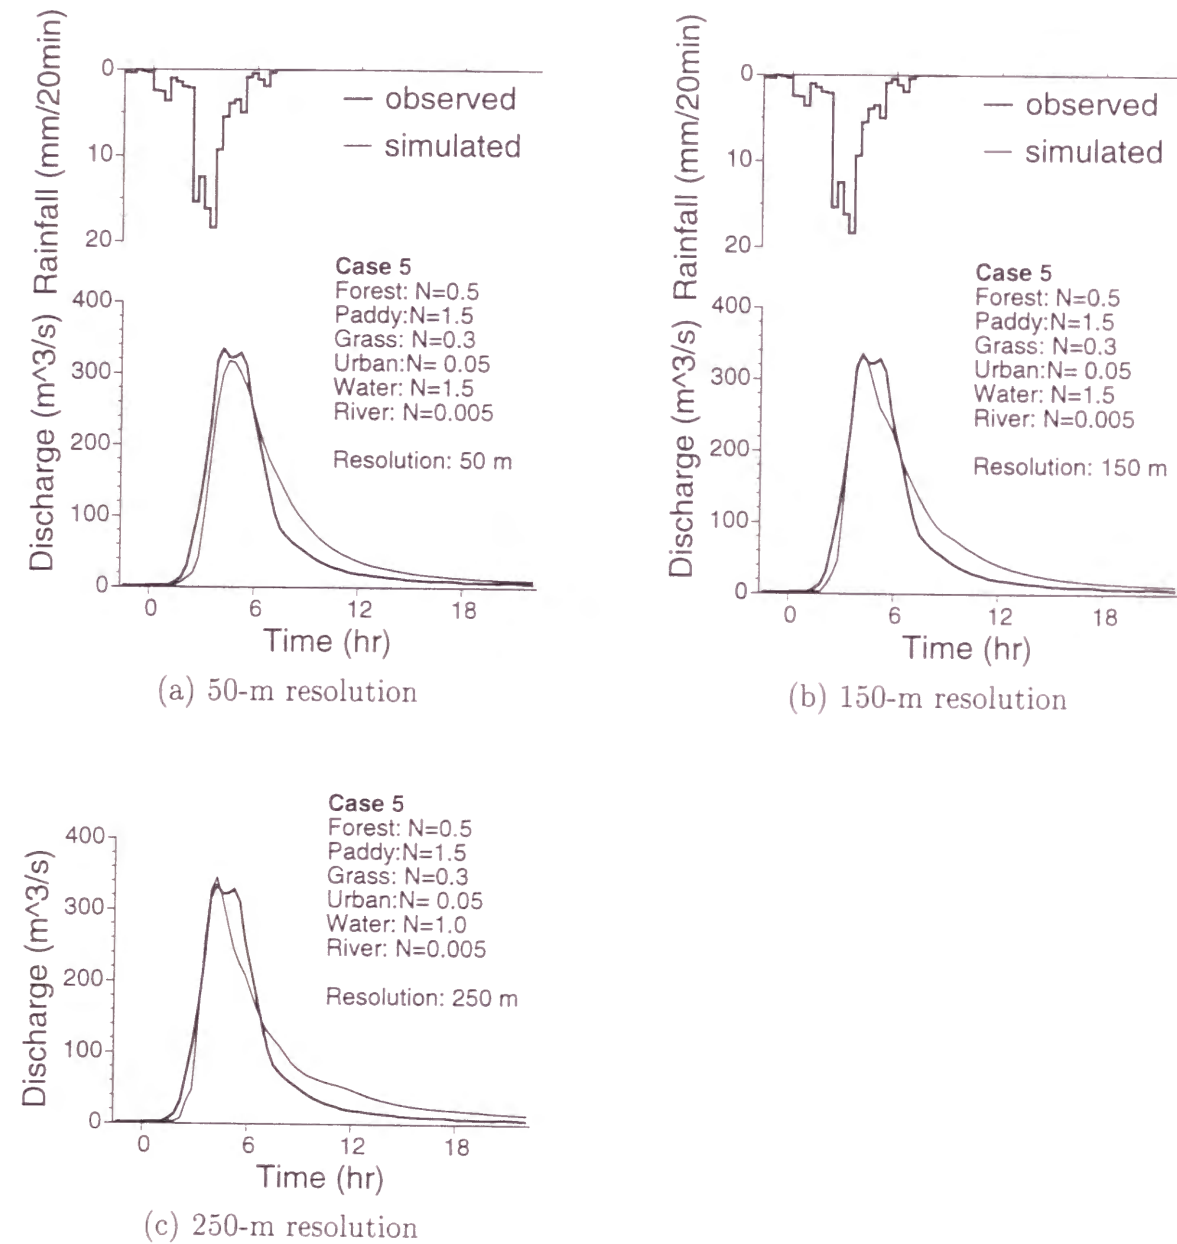


Figure 5.36 Observed and simulated hydrographs (Case 5).

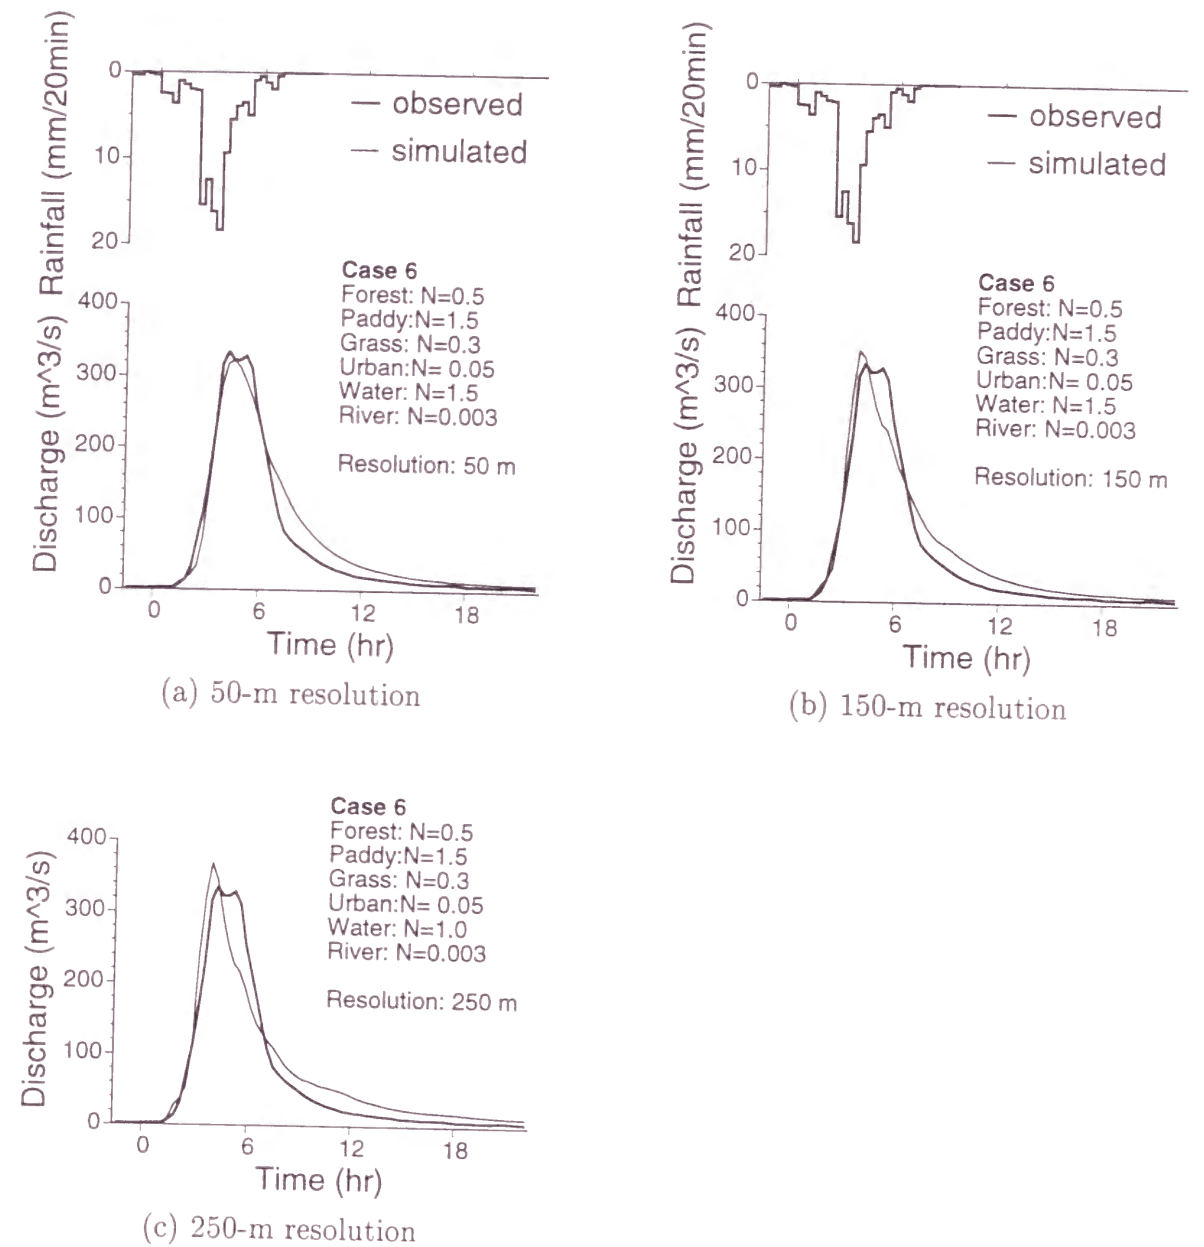


Figure 5.37 Observed and simulated hydrographs (Case 6).

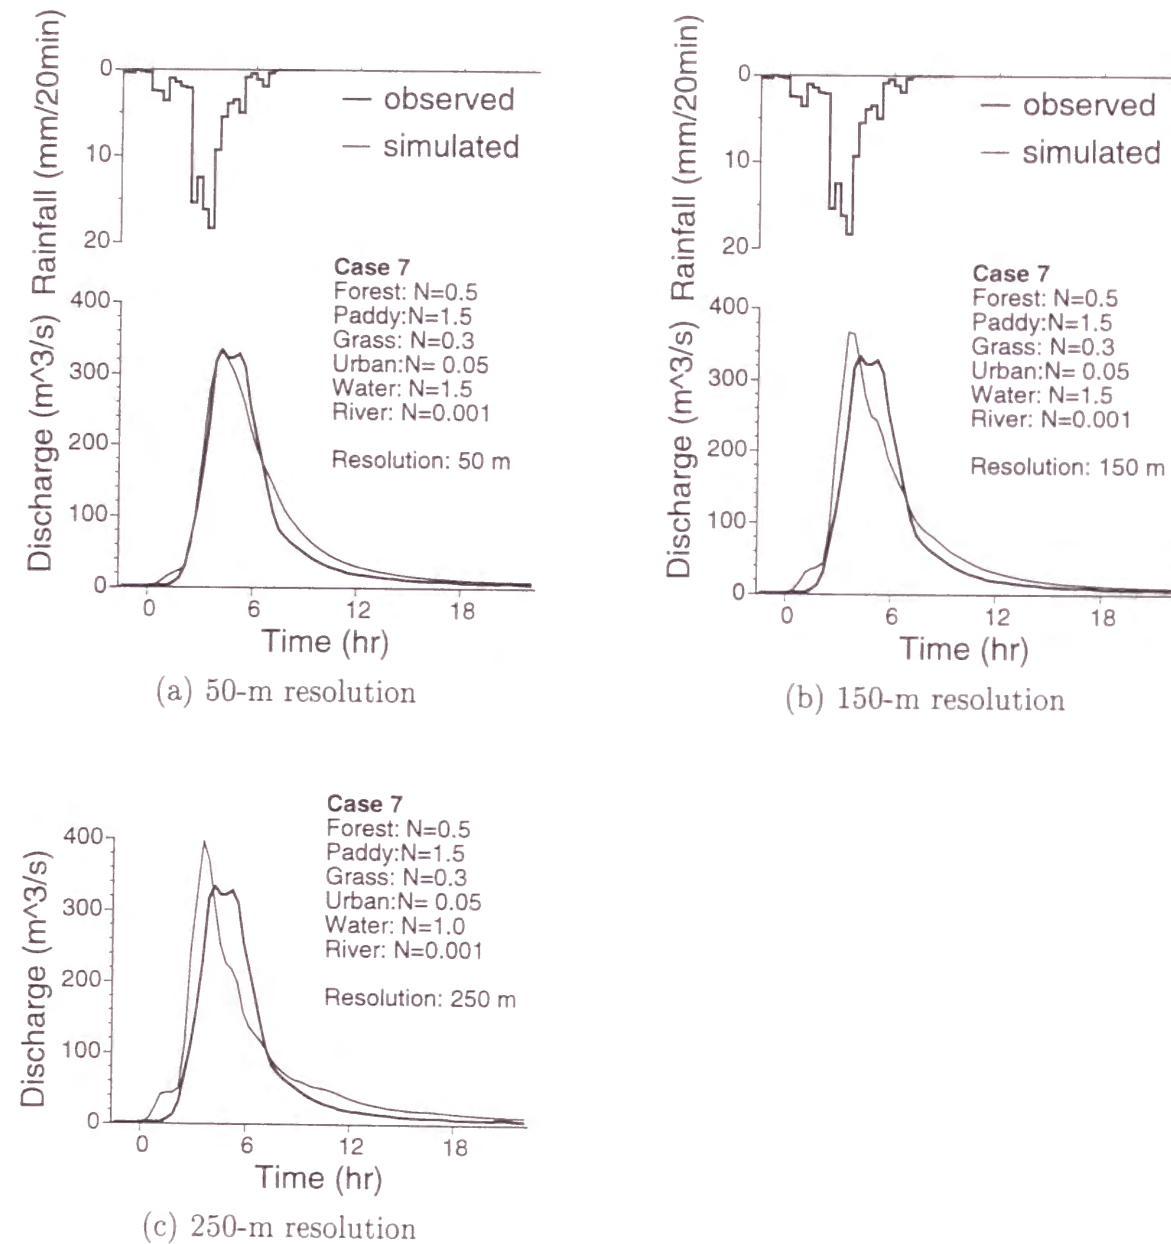


Figure 5.38 Observed and simulated hydrographs (Case 7).

ハイドログラフと観測ハイドログラフとの誤差をプロットした Figure 5.39 のような図を等価粗度ダイヤグラムと呼ぶことにする。Model B を用いて、都市域の等価粗度を 0.07~0.01, 河川の等価粗度を 0.007~0.001 の範囲で変えて計算を行った。ハイドログラフの誤差として、ピーク時刻の誤差の絶対値 (Figure 5.39), ピーク流量の誤差の絶対値 (Figure 5.40), 計算ハイドログラフと観測ハイドログラフの各ステップにおける RMSE (Figure 5.41) を採用した。

Figure 5.39~5.41 では、最小誤差、すなわち最もハイドログラフの精度が良い画素を黒で示し、最大誤差、すなわち最もハイドログラフの精度が悪い画素を白で示している。ピーク時刻の誤差は、どの分解能でも最小誤差は 0 分、最大誤差は 40 分であった。ピーク流量の誤差は、分解能 50 m では最小誤差は 0.5 m³/s, 最大誤差は 23.4 m³/s, 分解能 150 m では最小誤差は 0.1 m³/s, 最大誤差は 73.5 m³/s, 分解能 250 m では最小誤差は 1.1 m³/s, 最大誤差は 86.2 m³/s, RMSE では、分解能 50 m では最小誤差は 143.1 m³/s, 最大誤差は 322.7 m³/s, 分解能 150 m では最小誤差は 185.1 m³/s, 最大誤差は 383.2 m³/s, 分解能 250 m では最小誤差は 214.9 m³/s, 最大誤差は 449.8 m³/s であった。

Figure 5.39~5.41 から次のことが言える。

1. ハイドログラフの精度の良い等価粗度の組の領域と、精度の悪い等価粗度の組の領域が存在する。
2. ハイドログラフの精度の良い領域は、ダイヤグラムの対角方向に帯状に存在する。すなわち、河川と都市域の等価粗度は、トレードオフ関係になっている。
3. 分解能が粗くなるにつれて、ハイドログラフの精度の良い帯領域は、等価粗度の値が大きい側へシフトしていく。高分解能モデルでは適切な等価粗度の値は小さくなる。

Figure 5.40, Figure 5.41 では、精度の良い領域、悪い領域がよく見えるように、分解能ごとに同じ誤差でも違う色を与えていた。すなわち、ダイヤグラムごとに異なるグラデーションを与えていたが、異なる分解能でも同じグラデーションを与えると Figure 5.42, Figure 5.43 のようになる。それぞれ分解能 250 m のダイヤグラムと同じグラデーションを与えている。

分解能 50 m のダイヤグラム, Figure 5.42(a), Figure 5.43(a) では、ダイヤグラム全体が非常に暗くなっており、分解能 50 m のセル分布型モデルは、ハイドログラフの誤差の変動が少なく、常に精度が良いことを示している。逆に分解能が粗いと、ダイヤグラムの一部は暗いが、分解能 50 m に比べて明るい部分が広く、ハイドログラフの誤差の変動が激しいことが分かる。また、RMSE の最小誤差は、前述の通り、分解能 50 m では 143.1 m³/s, 分解能 150 m では 185.1 m³/s, 分解能 250 m では 214.9 m³/s であり、高分解能のセル分布型モデルほど高精度であるといえる。

また、Figure 5.39 に青, Figure 5.40 に緑, Figure 5.41 に赤を割り当てた図を Plate 5.20 に示す。Plate 5.20 で最も暗い画素が最も精度が良い等価粗度の組である。このようなカラー図を作成することで、容易に精度が良い等価粗度の組が見つかる。

RMSE で最も精度が良かったハイドログラフを Figure 5.44 に示す。分解能 150 m, 250 m のハイドログラフに対し、分解能 50 m のハイドログラフは、ピークの立ち上がりの流量




Figure 5.39 Diagrams for Peak Time errors.

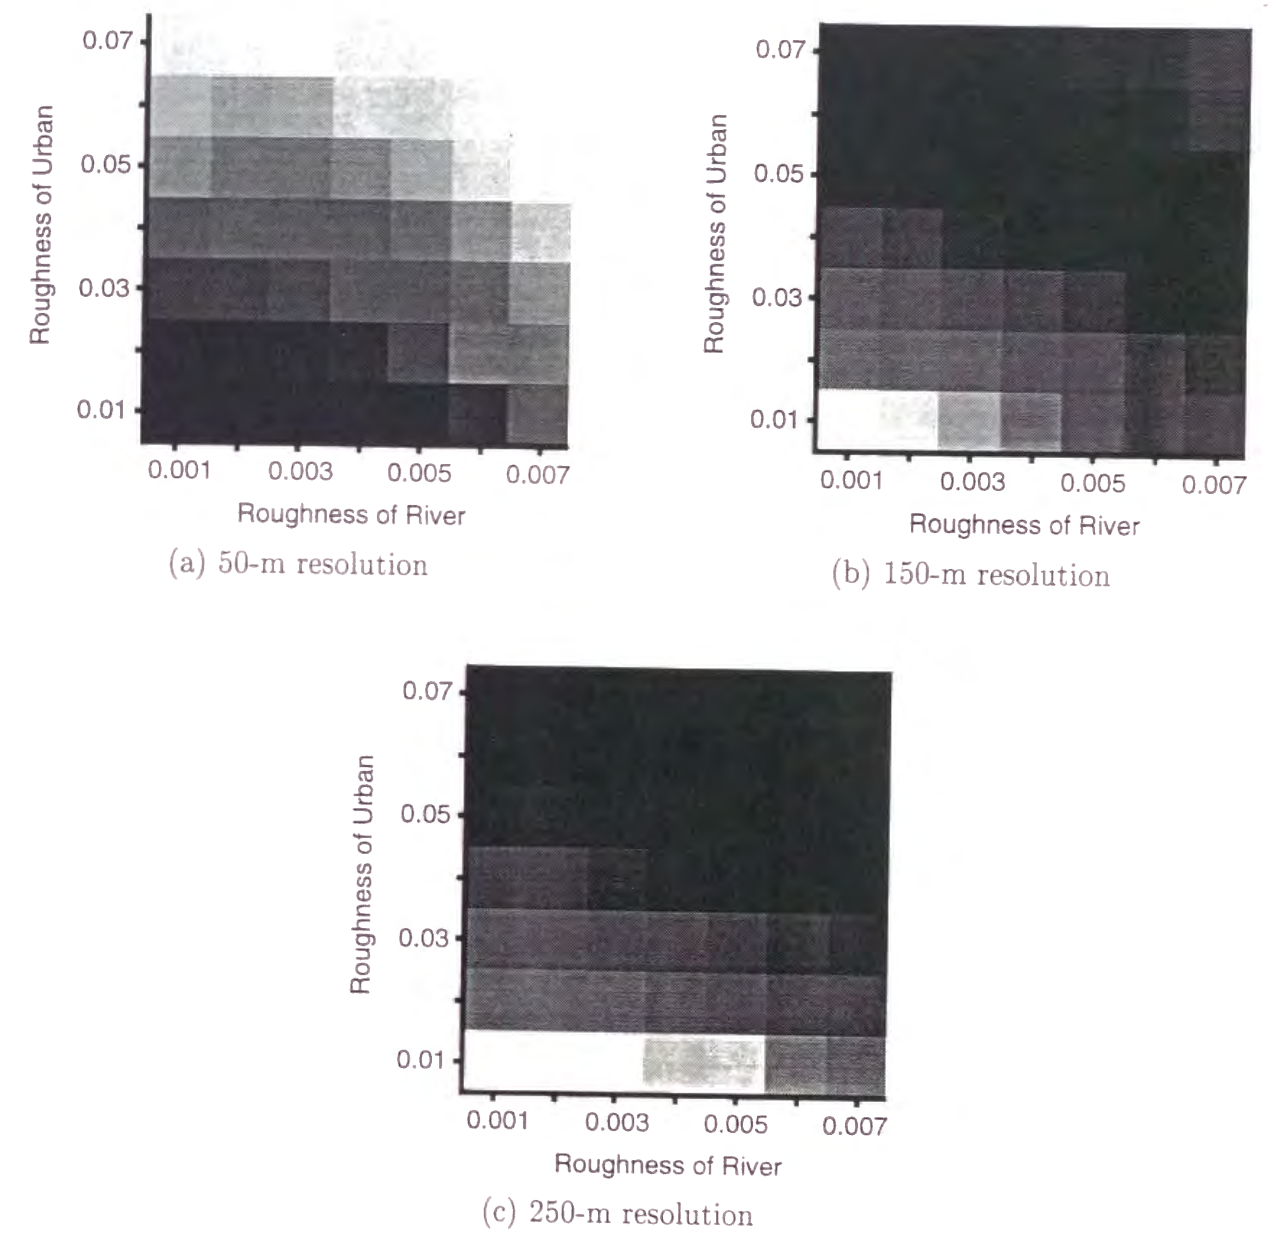


Figure 5.40 Diagrams for Peak Volum errors.





Figure 5.41 Diagrams for RMSE of hydrographs.




Figure 5.42 Diagrams for Peak Volum errors.




Figure 5.43 Diagrams for RMSE of hydrographs.

が、観測ハイドログラフと良く似ており、極めて精度がよいハイドログラフが計算されていることが分かる。

5.4.6 モデルの分解能と流出の遅れの関係

陸らの研究³⁾では、分解能が粗い方が流出が早くなるという報告がなされている。Model Bにおいてモデルの分解能と流出の遅れを比較すると、Case 1では分解能が粗い方が流出が遅く、Case 2では分解能が粗い方が流出が早いという結果が得られた (Figure 5.45)。Case 2では、陸らの研究と同じ結果が得られたが、Case 1では、逆の結果が得られた。Model Aでも Case 1では分解能が粗い方が流出が遅く、河道セルの等価粗度を小さくしていくとCase 7で分解能が粗い方が流出が早くなる。

さて、陸らは国土数値情報標高データを用いたメッシュベースの分布型洪水流出モデルを提案している。本研究のモデル (Model A 及び Model B) との相違点は以下の通りである。

1. セルからの流出は落水線で定められた流下方向であり、セルとセルの間は、幅 50 m の広幅矩形断面の仮想流路を仮定する。
2. 仮想流路への入力 は流路の上流端のみとし、セルからの直接流出成分 (すなわち有効降雨量) はすぐさま仮想流路の上流端へ入力される。

以上のルールに基づいた陸らのモデルを用いて、Case 1, 2 について流出計算を行った。

分解能 50 m と 250 m の計算結果を比較すると、Case 1 では分解能 250 m の方が 20 分だけ流出が遅いという結果が得られた。同様に Case 2 について比較すると、分解能 250 m と 50 m では流出のピークは同じという結果が得られた (Figure 5.46)。

以上の結果から、モデルの分解能と流出の遅れの関係は等価粗度の値の大きさによって変化し、等価粗度の値が大きいと分解能が粗いモデルの方が流出が遅くなり、等価粗度の値が小さいと分解能が粗いモデルの方が流出が早くなるといえる。

Figure 5.47に、主河道の流域最下流端からの距離と集水面積の関係を示す。分解能が粗い方が河道最下流端からの距離が同じ地点での集水面積が広がった。集水面積が広いということは、それだけ流量が増すわけであり、この結果からは、分解能が粗い 250 m のモデルの方が同一地点での流速も速く、流出も 250 m モデルの方が若干早いであろうということしか考察できない。また、各土地利用の流域全体に対する割合を Tabel 5.4に示す。分解能が粗くなると、粗度の値が小さい都市域の領域が広がっていることが目立つ。このことから分解能 250 m の方が流出が早くなるのではないかという推測しかできない。しかし、本研究の結果では、分解能が粗くなるにつれ、単純に流出が早くなるというわけではないことが分かった。

このような、モデルの分解能と流出の遅れの関係について考察するために、Figure 5.48のような 6×2 のセルをもつ仮想流域を考えた。この仮想流域では、縦に 6 つのセルが連結されてできた仮想斜面が横に 2 つ並んでおり、仮想流域からのハイドログラフは、2 つの仮想斜面の流出を合計して計算される。左右 2 つの仮想斜面 < Slope A > と < Slope B > の勾配が同じであるモデル α (Figure 5.49(a)) と、< Slope A > と < Slope B > の勾配が異な

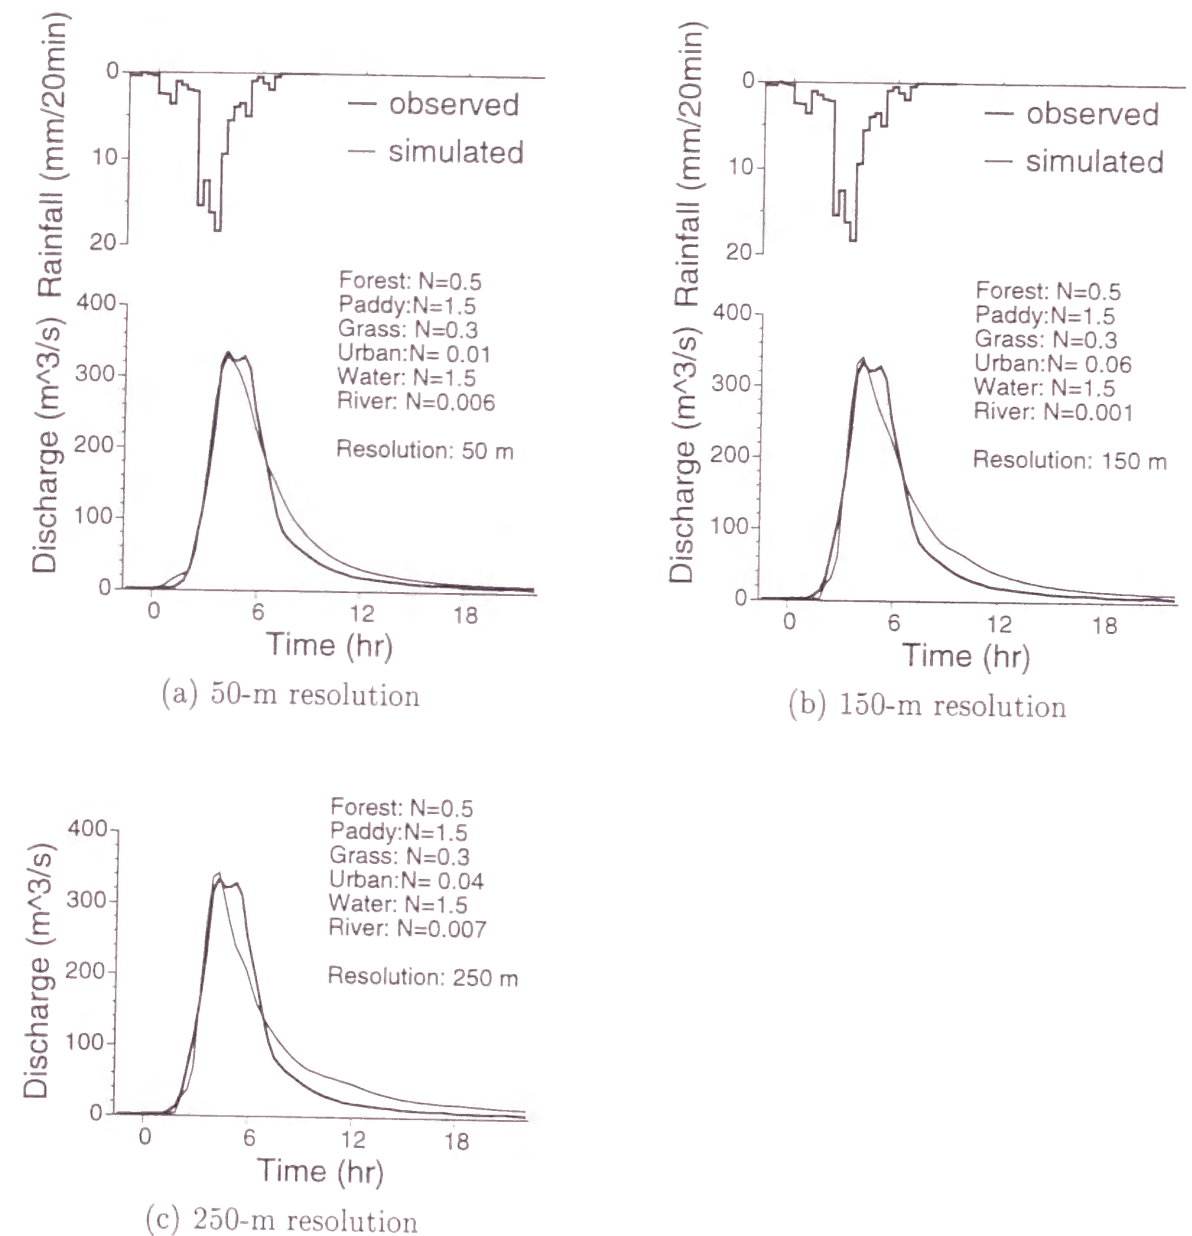


Figure 5.44 Simulated hydrographs with minimum RMSE.

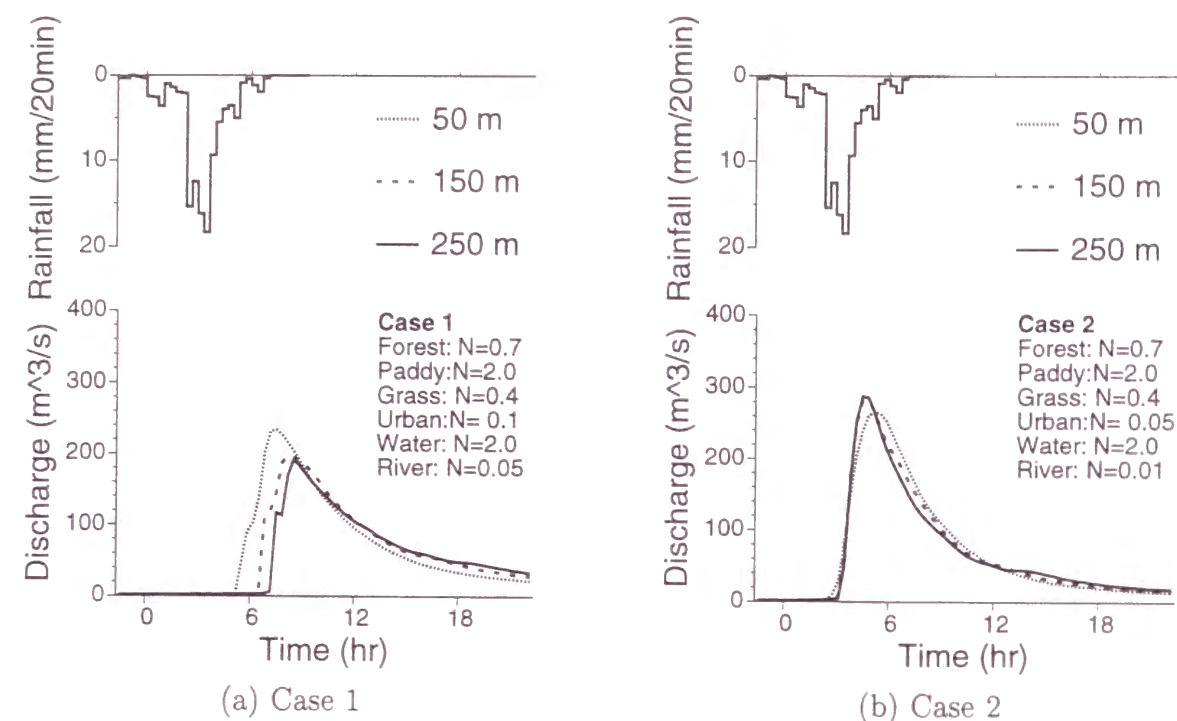


Figure 5.45 Simulated hydrographs using Model B.

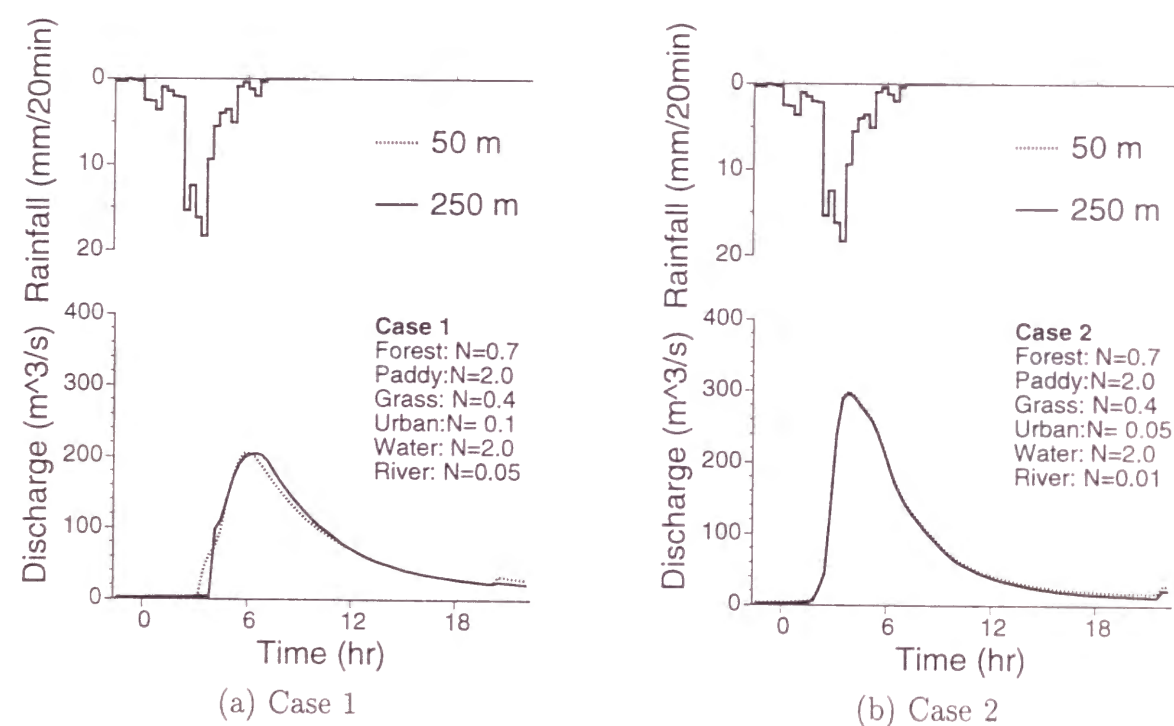


Figure 5.46 Simulated hydrographs using Lu model.

Table 5.4 Percentages of each land use

	50 m	250 m
Forest	0.234	0.204
Paddy	0.172	0.210
Grass	0.145	0.226
Urban	0.439	0.360
Water	0.009	0.000

るモデル β (Figure 5.49(b)) について考える。モデル β では、 $\langle \text{Slope B} \rangle$ の方が勾配が急で $\langle \text{Slope A} \rangle$ の方が勾配が緩やかである。モデル α の勾配は、モデル β の $\langle \text{Slope A} \rangle$ と $\langle \text{Slope B} \rangle$ の平均勾配とする。

ここで、モデル β が仮想流域の複雑な地形の変化をよく表していると考え、モデル α は仮想流域の地形の変化を平滑化したモデルだといえる。すなわち、モデル β は、地形の変化を忠実に再現する高分解能の流出モデルに対応し、モデル α は、地形の変化を単純化した低分解能の流出モデルに対応する。同じ斜面幅、斜面長、勾配、等価粗度をもつ斜面について計算する場合、高分解能セル分布型流出モデルと低分解能セル分布型流出モデルからは同じハイドログラフが計算されることが5.3.5項において実証されている。そのため、上記のモデル β において、 6×2 セルによって計算されるハイドログラフは、セルのサイズを大きくして 3×1 セルにした場合に計算されるハイドログラフと同等である。

さて、適当な矩形降雨を与えたとき、モデル α の $\langle \text{Slope A} \rangle$ (または $\langle \text{Slope B} \rangle$) から Figure 5.50(a) の左図のようなハイドログラフが得られたとすると、モデル α 全体では、Figure 5.50(a) の右図のようなハイドログラフが得られる。モデル β の $\langle \text{Slope A} \rangle$ は、モデル α の勾配よりも緩やかなので、Figure 5.50(a) の左図よりもピークの遅いハイドログラフが得られる。モデル β の $\langle \text{Slope B} \rangle$ は、モデル α の勾配よりも急なので、Figure 5.50(a) の左図よりもピークが早いハイドログラフが得られる (Figure 5.50(b) の左図)。モデル β 全体では、 $\langle \text{Slope A} \rangle$ 、 $\langle \text{Slope B} \rangle$ のハイドログラフを合計して、Figure 5.50(b) の右図の




Figure 5.47 Relation of channel length from outlet to drainage area.




Figure 5.48 Illustration of drainage path of the simulation basin.




Figure 5.49 Illustration of the simulation basins.

ようなハイドログラフが得られる。すなわち、モデル β の $\langle \text{Slope B} \rangle$ のハイドログラフのピーク時刻が最も早いのだが、 $\langle \text{Slope A} \rangle$ と $\langle \text{Slope B} \rangle$ のハイドログラフを合計すると、モデル α の方がモデル β のハイドログラフよりもピーク時刻が早いということになる。これは、地形の変化を平滑化している低分解能モデルの方が、地形の変化を再現している高分解能モデルの方よりもピーク時刻が早いという Model B の Case 2 の結果 (Figure 5.45(b)) に対応する。

上記の例では勾配の異なる3種の斜面のピーク時刻が近く、降雨が終了する前に全ての斜面でピークに達している。これは、各斜面の等価粗度が相対的に小さい場合の例であり、各斜面のピーク時刻は極めて接近している。これとは逆に、各斜面の等価粗度が相対的に大きく、流出が遅く、降雨が終了した後にピークに達する斜面がある場合には次のように考えられる。

モデル α の $\langle \text{Slope A} \rangle$ (または $\langle \text{Slope B} \rangle$) から Figure 5.51(a) の左図のようなハイドログラフが得られたとするとモデル α 全体では、Figure 5.51(a) の右図のようなハイドログラフが得られる。モデル β の $\langle \text{Slope A} \rangle$ は、モデル α の勾配よりも緩やかなので、Figure 5.51(a) の左図よりもピークの遅いハイドログラフが得られる。モデル β の $\langle \text{Slope B} \rangle$ は、モデル α の勾配よりも急なので、Figure 5.51(a) の左図よりもピークが早いハイドログラフが得られるこの場合、各斜面のピーク時刻は先ほどの例 (Figure 5.50) に比べて、相対的に離れていると考えられる。すると、モデル β 全体では、 $\langle \text{Slope A} \rangle$ 、 $\langle \text{Slope B} \rangle$ のハイドログラフを合計して、Figure 5.51(b) の右図のようなハイドログラフが得られる。すなわち、勾配の急な $\langle \text{Slope B} \rangle$ のピーク流量は、勾配の緩やかな $\langle \text{Slope A} \rangle$ のピーク流量よりも多く、また、2つのピークは離れているため互いに干渉せず、結果としてモデル β 全体のピークは $\langle \text{Slope B} \rangle$ のピークと同じになる。

モデル α の $\langle \text{Slope A} \rangle$ および $\langle \text{Slope B} \rangle$ の勾配を $1/50$ 、モデル β の $\langle \text{Slope A} \rangle$ の勾配を $1/100$ 、 $\langle \text{Slope B} \rangle$ の勾配を $3/100$ としたときの計算ハイドログラフを Figure 5.52 に示す。等価粗度の値を 0.2 と小さくし、各斜面のピーク時刻を接近させたときの計算ハイドログラフは、Figure 5.52(a) のようになり、モデル α の方がピーク時刻が早いという理論通りの結果となった。実際の地形をよく再現しているモデル β の方が観測ハイドログラフをよく再現していると考え、モデル α の計算ハイドログラフのピーク時刻をモデル β のピーク時刻に合わせようとする、モデル α に用いる等価粗度は、モデル β の等価粗度よりも相対的に大きい値となる。

等価粗度の値を 2.0 と大きくしたときの計算ハイドログラフを、Figure 5.52(b) に示す。矩形降雨を与えた場合、ピーク時刻は常にどの斜面でも降雨終了時刻と同じになるため、凸型の降雨を与えてみた。ピーク付近を拡大すると (Figure 5.52(b) の右図)、モデル α の方がピーク時刻が遅くなっていることが分かる。

以上の仮説は、ピーク時刻のみに着目したもので、ピーク流量やハイドログラフの RMSE については説明できていない。しかし、高分解能のモデルと低分解能のモデルは、地形の変化を再現しているか、単純化しているかが異なるという点に着目した以上の考察によって、矢田川流域において得られた

1. 分解能が粗いモデルは等価粗度の感度が鋭く、高分解能モデルでは等価粗度の感度が



(a) Simulation model α (b) Simulation model β

Figure 5.50 Suppositional hydrographs on the simulation basins.





(a) Simulation model α (b) Simulation model β

Figure 5.51 Suppositional hydrographs on the simulation basins.



(a) roughness coefficient is smaller



(b) roughness coefficient is larger

Figure 5.52 Simulation hydrographs on the simulation basins.

鈍い。

2. 分解能が粗くなるにつれて、ハイドログラフの精度の良い帯領域は、等価粗度の値が大きい側へシフトしていく。高分解能モデルでは適切な等価粗度の値は小さくなる。

という知見について、その現象の一端を説明することができたと考えられる。

5.5 結語

本章では、DEMのグリッド交点の周囲の正方形の領域を1つの部分流域(セル)と考え、セルが多数集まって流域を構成するセル分布型流出モデルを提案し、さらにそのセルのサイズが、流出解析結果にどう影響するかについて検討を行った。

各土地利用クラスの等価粗度の値を変化させて、計算ハイドログラフの感度分析を行ったところ、高分解能のセル分布型流出モデルの方が感度が鈍く、多少等価粗度の値を変えても、比較的良好なハイドログラフが得られた。次に、森林、水田、草地、水域クラスの等価粗度の値を固定し、都市域、河川クラスの等価粗度の値を変化させて計算し、観測ハイドログラフと計算ハイドログラフの誤差を図にした、等価粗度ダイヤグラムによって感度分析を行った。高分解能のセル分布型流出モデルの方が感度が鈍く、RMSEの最小値は最も高分解能の分解能50mで現れた。以上より、セル分布型流出モデルでは、そのセルサイズが小さいほど計算ハイドログラフの精度は良く、等価粗度の感度が鈍く多少値が異なってもよい結果が得られ、セルサイズが大きいと等価粗度の感度が鋭いため、よい結果を得るためには試行錯誤的な繰り返し計算が多数必要であると言える。また、高分解能の流出モデルでは、都市域と河川クラスの等価粗度の値が小さいとき計算ハイドログラフの精度が良く、低分解能の流出モデルでは、等価粗度の値が比較的大きいとき精度が良いという結果が得られた。

セル内の流出をkinematic wave法で求めるセル分布型流出モデルは、陸ら³⁾も提案している。しかし、陸らのモデルでは、セル内での流出を考える際、一つのセルへの降雨は全てそのセルの上流端から入力され、横流入は無しと考える便宜的なモデルである。本研究のモデルは、kinematic wave法の基礎式((5.1), (5.2)式)をLax-Wendroff型の差分スキーム⁵⁾で解き、セル内に設けたnodeそれぞれにおいて降雨を入力する横流入を取り扱っており、kinematic wave理論に基づく流出現象を忠実に計算するものである。

陸らは、分解能が粗くなると流出が早くなると報告しているが、本研究の結果からは、モデルの分解能と流出の遅れの関係は等価粗度の値の大きさによって変化し、等価粗度の値が大きいと分解能が粗いモデルの方が流出が遅くなり、等価粗度の値が小さいと分解能が粗いモデルの方が流出が早くなるということが分かった。また、モデルの分解能と流出の遅れの関係は、高分解能のモデルは地形の変化を再現しているが、低分解能のモデルはそれを単純化していることが原因であるという仮説を立て、数値実験によりその仮説を証明することができた。

参考文献

1) 高棹琢馬・宝 馨・溝渕伸一・杉原宏章：国土数値情報を用いた水文地形解析に関する基礎的研究，京都大学防災研究所年報，Vol. 32, No. B-2, pp.435-454, 1989.

2) Sunada, K. and S. Fukui：Study on dependence of runoff model parameters on the scale of catchment element, *International Conference on Water Resources & Environment Research: Towards the 21th Century (Volume I)*, Water Resources Research Center, Kyoto University, Japan, pp. 293-300.

3) 陸 旻皎．小池俊雄・早川典生：分布型水文情報に対応する流出モデルの開発，土木学会論文集，Vol.411, No. II-12, pp. 135-142, 1989.

4) 建設省河川局 (監)：建設省河川砂防技術基準（案）調査編，山海堂，p. 144, 1977.

5) 椎葉充晴：流出系のモデル化と予測に関する基礎的研究，京都大学学位論文，pp. 18-20, 1983.

6) 財団法人河川情報センター：降雨・流出予測モデル検討業務報告書，1990.

7) 角屋睦：流出解析法 (その 1) -1. 雨水流出現象とその計測・解析-，農業土木学会誌，Vol. 47, No. 10, pp. 135-142, 1979.

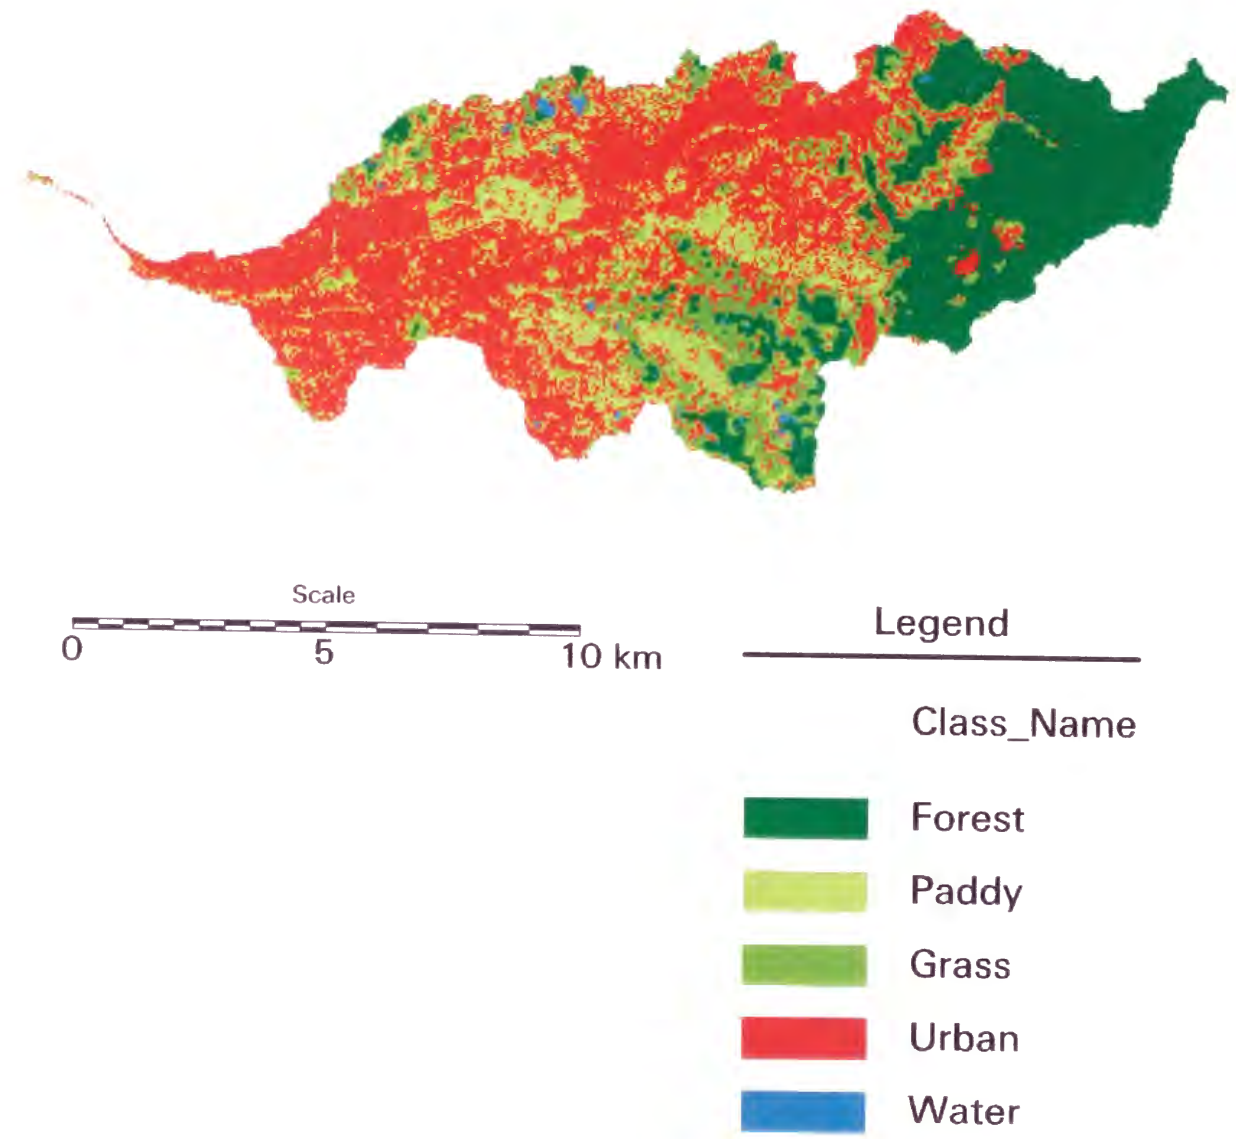


Plate 5.13 Landuse classification with 50-m resolution.




Plate 5.14 Land use classification with 150-m resolution.



Plate 5.15 Land use classification with 250-m resolution.

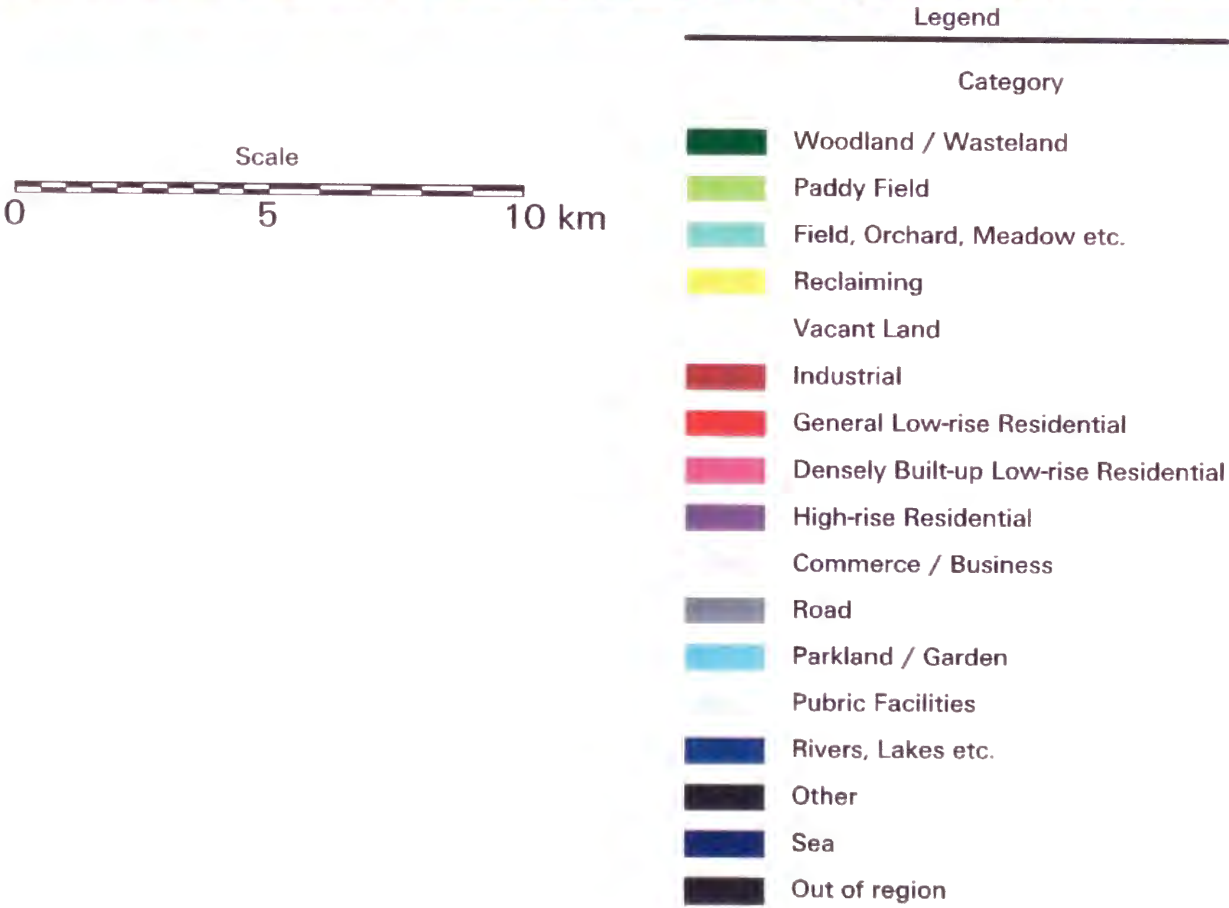



Plate 5.16 Detailed Digital Land use map in the Yada River Basin.




Plate 5.17 Land use classification to 4 classes with 150-m resolution.



Plate 5.18 Land use classification to 4 classes with 250-m resolution.

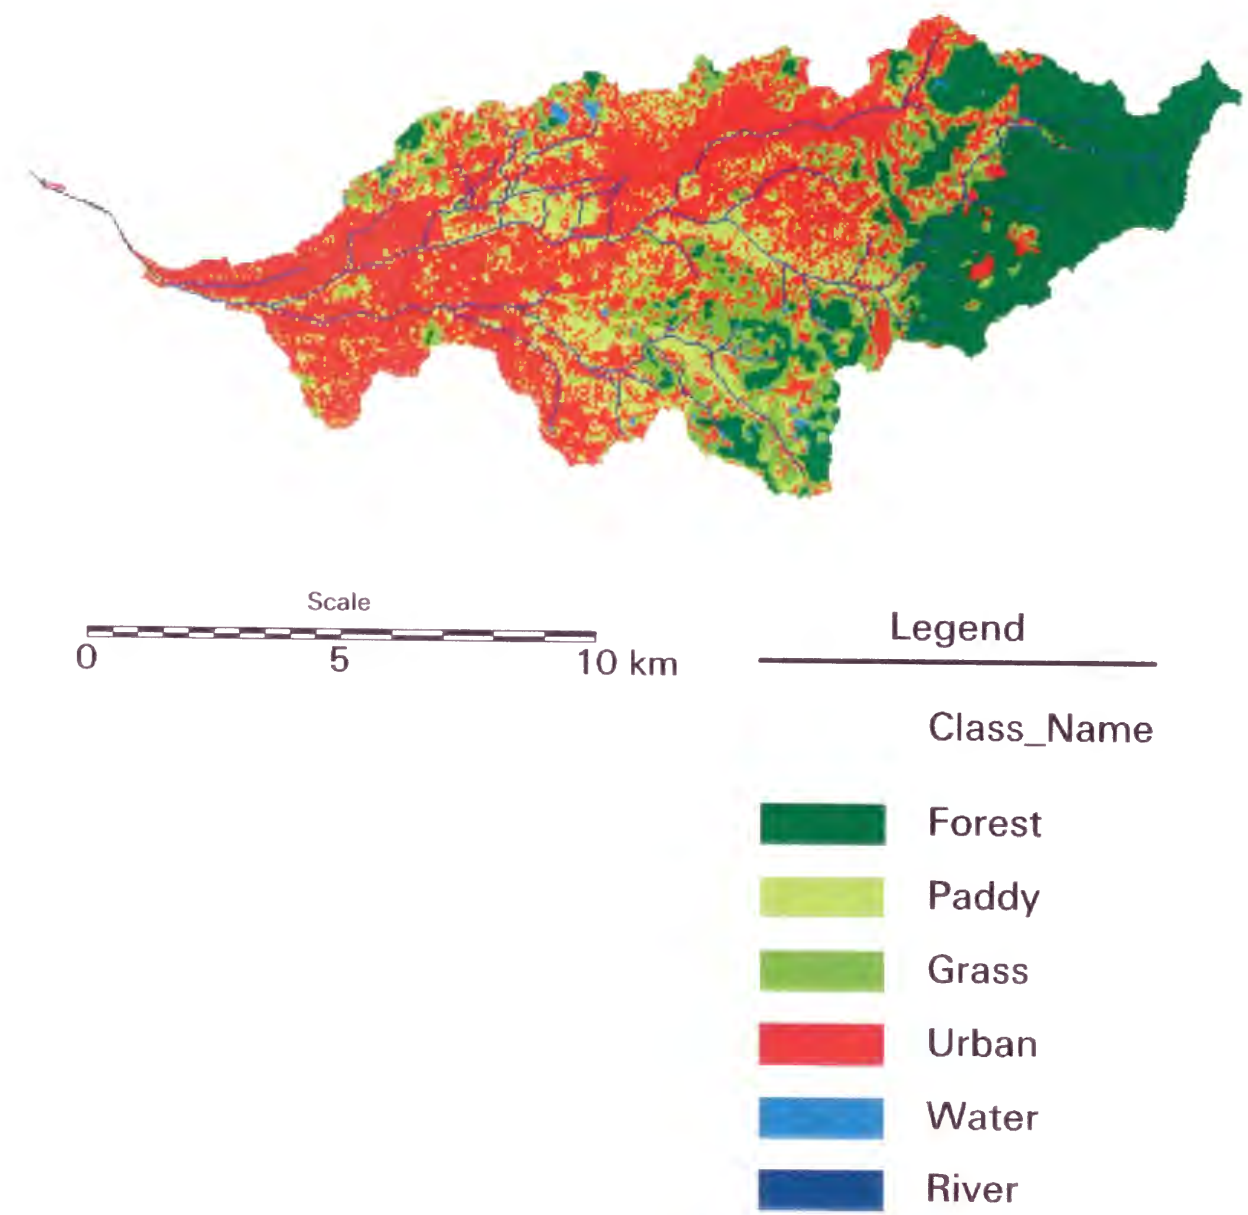


Plate 5.19 Land use classification to 6 classes with 50-m resolution.




Plate 5.20 Diagrams for errors of simulated hydrograph.

第 6 章

結論

水文解析に有効な情報として、リモートセンシングデータや DEM、土地利用情報などのラスタ型空間情報は今後ますますその重要度が高まると思われる。本研究は、リモートセンシングデータおよびラスタ型空間情報を応用したいいくつかの水文解析手法の提案・検討を行った。

近年、地球環境の危機が叫ばれ、地球規模での水循環の解明が重要視され、地点・地域といった比較的狭い範囲の空間情報を如何に広い範囲に拡張するかということが一つの重要な課題となっている。これをふまえて、特に本研究では、高空間分解能のラスタ型情報とそれを空間的にスケールアップした低分解能ラスタ型情報を解析に用い、ラスタ型空間情報の分解能が水文解析結果に影響について考察した。以下に得られた知見を要約し、結論とする。

まず、第 2 章では、ラスタ型空間情報のスケールアップ、すなわち低分解能化の手法について考察した。ラスタ型空間情報にはいくつかの種類があり、スケールアップを行うには、そのラスタ型空間情報の種類に応じたアルゴリズムを用いる必要があることを示した。水文解析によく用いられるラスタ型データには、リモートセンシング画像、DEM、土地利用図、土壌分類図等が挙げられる。リモートセンシング画像のスケールアップには MTF を応用したアルゴリズム、DEM に対しては、内挿法を用いたアルゴリズムが適当である。土地利用図、土壌分類図などの主題図には、最大頻度に基づく方法が適当である。

第 3 章では、リモートセンシング画像の水文解析への応用手法として最も基本的な、土地被覆分類を取り上げ、土地被覆分類精度とリモートセンシング画像の空間分解能との関係について考察した。

空間分解能が異なっても位置誤差と波長帯の違いのない画像を比較するため、6.25 m の分解能をもつ航空機 MSS 画像から、10 m から 30 m の分解能をもつ疑似リモートセンシング画像を生成した。2 m 刻みという細かく分解能が変化する際の分類精度の変化を検討したところ、総合精度 (OA) および kappa 係数 (KC) は分解能 12 m において最も精度が良く、分解能が粗くなるにしたがって分類精度は低下していく様子が確認できた。また、最も精度が良かった分解能 12 m の分類精度と分解能 30 m の画像と比較すると OA、KC で約 6 ポイント程度向上することが確認できた。

次に、ADEOS/AVNIR(分解能 16 m) の疑似画像を生成し、その分類精度を Landsat/TM

(分解能 30 m) と比較した。今後打ち上げられる、様々な分解能のセンサーも、本研究と同様の手法によって疑似画像を生成し、その分類精度を予測することが可能であることを示した。

第4章では、リモートセンシング画像から蒸発散量を推定する手法についての考察を行った。都市域・森林・耕作地が混在する領域に対して、高空間分解能のリモートセンシング画像から、分解能の異なる疑似リモートセンシング画像を生成した。生成した疑似画像から NDVI を算定し、さらに NDVI と月蒸発散量の線形関係式を用いて月蒸発散量を算定した。

分解能 6.25 m から 2 km の疑似画像による解析結果を比較したところ、NDVI およびそれに基づく月蒸発散量の領域平均値は分解能によってあまり変化しなかった。このことから、数 100km² の領域の月蒸発散量を、リモートセンシング画像から得られる NDVI を基に推定する場合には、数 m から数 km 程度までのどの分解能で考えてもそれほど問題は無いと思われる。

また、線形の NDVI と月蒸発散量の関係式を用いたところ、高分解能リモートセンシング画像からは極端に推定値が高すぎたり、0mm/month となる領域が発生した。高分解能リモートセンシング画像を用いた月蒸発散量の推定には、線形ではなく、ある上限値、下限値に漸近していく NDVI と月蒸発散量の関係式が必要であることが分かった。しかし、1 km 程度より粗いリモートセンシング画像を用いた場合は、平滑化の影響によって、関係式を線形で仮定できるという結果が得られた。

次に、領域内の土地被覆の割合のみから蒸発散量を推定する F-C-U ダイアグラムを提案した。F-C-U ダイアグラムと 2 km メッシュ全国土地利用データセットを用いることにより、1900 年頃から 1950 年頃、現代となるにつれて、名古屋市周辺の月蒸発散量が減少していることが示された。

第5章では、DEM のグリッド交点の周囲の正方形の領域を 1 つの部分流域 (セル) と考え、セルが多数集まって流域を構成するセル分布型洪水流出モデルを提案し、さらにそのセルのサイズが、流出解析結果にどう影響するかについて検討を行った。流域内の各セルの土地被覆情報をリモートセンシング画像の土地被覆分類結果から得た。土地被覆分類クラスごとに等価粗度を与え、各セルの等価粗度を決定した。DEM は斜面勾配、雨水の流下方向を決定するために用いた。

各土地利用クラスの等価粗度の値を変化させて、計算ハイドログラフの感度分析を行ったところ、高分解能のセル分布型流出モデルの方が感度が鈍く、多少等価粗度の値を変えても、比較的良好なハイドログラフが得られた。

次に、森林、水田、草地、水域クラスの等価粗度の値を固定し、都市域、河川クラスの等価粗度のみを変化させて計算し、観測ハイドログラフと計算ハイドログラフの誤差 (RMSE, ピーク時刻の相対誤差, ピーク流量の相対誤差) を求めた。その結果、最も高分解能の分解能 50 m の流出モデルによる計算ハイドログラフが最も精度が良く、最も低分解能の分解能 250 m の流出モデルが最も精度が悪いという結果が得られた。

セル分布型流出モデルでは、高分解能のモデルの方が精度の良いハイドログラフが得られる。低分解能のモデルでは、と等価粗度の感度が鋭いため、よい結果を得るためには試行錯誤的な繰り返し計算が多数必要であると言える。

また、モデルの分解能と流出の遅れの関係は等価粗度の値の大きさによって変化し、等

価粗度の値が大きいと分解能が粗いモデルの方が流出が遅くなり、等価粗度の値が小さいと分解能が粗いモデルの方が流出が早くなるということが示された。

本研究では、リモートセンシング画像、ラスタ型空間情報の水文解析へ応用する際に、その空間分解能が解析結果にどう影響するかを応用例を示し、検討を行った。リモートセンシングデータや、ラスタ型、ベクター型の広域の空間情報は、近年、水文解析へ急速に取り入れられつつある。しかし、リモートセンシングデータはまだ新しい分野であり、どのように応用すればよいかを模索している段階である。そのため、リモートセンシングデータの空間分解能が解析結果に及ぼす影響についての考慮は、あまりなされないのが現状である。

本研究で示した応用例、空間分解能の違いによる解析結果の相違などの知見は、愛知県の庄内川流域の一部における結果であり、場所的・時期的に普遍性のあるものにするにはさらなる検証が必要である。しかしながら、河川流域において空間的に分布する物理量やパラメータとリモートセンシング画像の空間分解能との関係を把握しておくことは、水文流出系の地域規模・地球規模での解析において基本的に重要である。本研究の成果がリモートセンシングと水文学の一助となることを期待しつつ、今後なお一層の精進を続けたいと願っている。

謝 辞

本研究の遂行をととして、終始懇切なるご指導を賜った京都大学防災研究所 岡 太郎 教授ならびに宝 馨 助教授に深甚なる謝意を表します。京都大学防災研究所 池淵周一 教授、京都大学工学部 椎葉充晴 教授には、研究の細部にわたり数多くのご教授を賜り、深く感謝いたします。岡山大学理工学部 近森秀高 助教授、京都大学防災研究所 中北英一助 教授、友杉邦雄 助教授、大石 哲 助手、石井将幸 助手には、折にふれて様々なご助言をいただくとともに、暖かいご支援をいただきました。ここに、心から謝意を表します。また、京都大学防災研究所 小尻利治 教授には、岐阜大学修士の頃より、数多くのご教授をいただき、深く感謝いたします。

本研究で用いた、「2km メッシュ日本全国土地利用データセット」は、北海道教育大学の氷見山幸夫教授が作成されたもので、UNEP/GRID を通じ、国立環境研究所、地球観測研究センター、GRID-つくばから提供されたものである。ここに記して謝意を表します。

また、研究遂行に当たって数々の有益なご助言とご協力を賜った京都大学防災研究所水資源研究センターの先生方および諸兄に改めて厚く感謝いたします。